



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

NÖROBİLİM ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**"İKİ SERBESTLİK DERECELİ HAREKET KONTROLÜ İÇİN
ZİHİNSEL GÖREV SINIFLANDIRMA TABANLI BEYİN-BİLGİSAYAR
ARAYÜZÜ TASARIMI"**

Çağlar UYULAN

Tez Danışmanı

Yrd.Doç.Dr, Türker Tekin ERGÜZEL

İSTANBUL-2016

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

NÖROBİLİM ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**"İKİ SERBESTLİK DERECELİ HAREKET KONTROLÜ İÇİN
ZİHİNSEL GÖREV SINIFLANDIRMA TABANLI BEYİN-
BİLGİSAYAR ARAYÜZÜ TASARIMI"**

Çağlar UYULAN

Tez Danışmanı

Yrd.Doç.Dr, Türker Tekin ERGÜZEL

İSTANBUL-2016

T.C.

ÜSKÜDAR ÜNİVERSİTESİ

SAĞLIK BİLİMLERİ ENSTİTÜSÜ

Nörobilim Anabilim Dalı Nörobilim Yüksek Lisans Programı çerçevesinde yürütülmüş olan bu çalışma aşağıdaki jüri tarafından 01.07.2016 tarihinde yapılan sınavda Yüksek Lisans Tezi olarak oybirliği ile kabul edilmiştir.

Danışman: Yrd.Doç.Dr.Türker Tekin ERGÜZEL

Üsküdar Üniversitesi

İmza

Üye: Yrd.Doç.Dr.Türker Tekin ERGÜZEL

Üsküdar Üniversitesi

İmza

Üye: Yrd.Doç.Dr.Ümit TAŞ

Üsküdar Üniversitesi

İmza

Üye: Yrd.Doç.Dr.Belkıs Atasever ASLAN

Üsküdar Üniversitesi

İmza

ONAY

Bu tez, yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun tarih ve sayılı kararıyla kabul edilmiştir.

İmza

Enstitü Müdürü



ÖZET

Bu tezde, bilgisayar ortamında oluşturulmuş bir nesnenin, alfabenin tersten sayılması, küpün zihinsel olarak döndürülmesi, sağ el hareketini düşünülmesi, sol kol hareketinin düşünülmesi ve matematiksel işlemlerin yapılması ile iki eksen üzerinde, sağ, sol, yukarı ve aşağı yönlerde hareket etmesini sağlayan bir beyin-bilgisayar arayüzü tasarlanmış ve bu beyin-bilgisayar arayüzü aracılığı ile gerçek-zamanda, verili yörüngelerin takibi yapılmıştır.

Öncelikle, kullanıcıdan alınan EEG sinyalleri, Emotiv şirketi tarafından üretilen EPOC kulaklığı ile gerçek-zamanlı olarak kaydedilmiştir. Başlık, beynin her iki yarımküresinde yedişer adet olmak üzere toplam 14 kanal içermektedir. Kaydedilen bu veriler Matlab ortamına aktarılıp sırasıyla filtreleme, öznitelik çıkartma, öznitelik indirgeme, öznitelik seçimi, sınıflandırma ve kontrol sinyaline kodlama işlemlerinden geçirilmiştir. Veriler kaydedilirken "Matlab&Simulink" ortamı ile etkileşen bir beyin-bilgisayar arayüzü olan "Simulink EEG Importer" programı kullanılmıştır. Bu sayede, EPOC kulaklığından gelen, gerçek-zamanlı EEG verileri "Matlab&Simulink" simülasyon modeline aktarılabilir. Simulink bloğu, EEG datasını bir vektör formatında almakta ve sonraki sinyal işleme aşamaları için Simulink ortamında tutmaktadır. Örnekleme frekansı 128 Hz.'dir. Ham data, artefakların ve gürültülerin ortadan kaldırılabilmesi için, öncelikle 50 Hz.'lik "bant durdurucu" filtreden, sonra da 0.5-45 Hz.'lik kesim frekanslarına sahip 6.dereceden "Butterworth bant-geçiren" filtreden geçirilerek filtrelenmiştir.

Özniteliklerin çıkartılmasında, 7. seviyede "Daubechies-4" dalgacık fonksiyonu tabanlı dalgacık paketi ayrıştırması ve "Symlet-2" dalgacık fonksiyonu tabanlı dalgacık filtre bankası metotları uygulanmıştır. Çıkartılan özniteliklerin boyutu, temel bileşenler analizi ile indirgenmiştir. Öznitelik vektörleri, geri yayılım algoritmasını kullanan, çok katmanlı algılayıcı yapay sinir ağı ile sınıflandırılmıştır.

Zihinsel görevler gerçekleştirilirken, her bir zihinsel görev için 0-30 saniye aralığında 40 epokluk eğitim datası ve 10 epokluk test datası toplanmıştır. Daha sonra bu veriler 1'er saniyelik parçalara bölünerek toplamda $14(\text{sensörkanalı}) \times [4(\text{görev}) * 40(\text{epok}) * 31(\text{saniye})]$ eğitim veri matrisi ve $14(\text{sensörkanalı}) \times [4(\text{görev}) * 10(\text{epok}) * 31(\text{saniye})]$ test veri matrisi elde edilmiştir.

Yapay sinir ađı için seilmiř parametreler; 190 n6ronlu 1 gizli katman, 0.03'l6k 6đrenme oranı ve 0.2'lik momentum oranı, performans kriteri "mse" olarak belirlenmiř, eđitim algoritması, "6lekli paylařım gradyanı" olarak seilmiřtir.

Eđitim seti 6rneđinin %60'ı eđitim, %20'si dođrulama ve %20'si de test iin kullanılmıřtır. Bu sınıflandırma sonucunda, beyin-bilgisayar aray6z6 y6r6nge takibi kontrol6 iin giriř sinyalleri elde edilmiřtir. Y6r6nge takibi kontrol stratejisi, "sađ-sol-yukarı-ařađı" y6nlerde hiyerarřik olarak yapılmıřtır. Deneysel testler, verilen referans y6r6ngenin takibini sađlayacak řekilde gerekleřtirilmiřtir.

Dalgacık filtre bankası 6znelik ıkartma metodu ile gerekleřtirilen sınıflandırmada, en iyi eđitim ve test veri k6meleri iin, kapalı-evrimde %89.6'lık, aık-evrimde ise %81.5'lik sınıflandırma dođruluđu elde edilmiřtir.

Dođruluk deđerini arttırmak iin, paracık s6r6 optimizasyonuna dayalı 6znelik seimi uygulanmıřtır. Bunun sonucunda aık-evrim sınıflandırma dođruluđu %82.94 ve Kappa deđerini 0.776 olarak elde edilmiřtir. Beyin-bilgisayar aray6z6 y6r6nge takibine iliřkin rekognisyon performansı da 4 zihinsel g6rev iin %81.38 olarak elde edilmiřtir. oklu zihinsel g6rev deđiřtirilmesine dayalı, gerek-zamanlı y6r6nge takibine iliřkin "normalize edilmiř hatanın karesinin ortalamasının karek6k6" deđerini, 0.2818 olarak hesaplanmıřtır. Ayrıca, oklu zihinsel g6rev deđiřtirilmesi yolu ile, belirlenen hedeflere ulařılmıřtır.

Anahtar Kelimeler: Beyin-bilgisayar aray6z6, 6znelik ıkartma, 6znelik seimi, Hiyerarřik kontrol, Zihinsel g6rev sınıflandırma

ABSTRACT

In this thesis, brain-computer interface, which controls the movement of an object created in a software environment in two axis through right, left, up and down directions via four mental tasks (reciting the alphabet backwards, imagination of rotation of a cube/motor imagery of right hand movement, motor imagery of left arm movement, performing mathematical operations) has designed and the trajectory tracking in real-time has been performed.

Primarily, EEG signals acquired from user was recorded with Emotiv-EPOC neuro-headset in real-time. The headset consist of 14 electrode channel, which is located equally in both of two hemisphere. The recorded data were transfered into the Matlab environment and filtering, feature extraction, feature reduction, feature selection, classification, decoding into control signal, processes have been realized, respectively.

While recording data, "Simulink EEG Importer" program, which interacts with the "Matlab&Simulink" was used. By the help of this program, EEG data obtained from EPOC neuro-headset can be directed real-time into the "Matlab&Simulink" simulation model. The simulink model receives the EEG data in vector format and holds in Simulink environment for later signal processing. The sampling frequency is 128 Hz.

The raw data has been filtered by using a bandstop filter with a 50 Hz. cut-off frequency and a Butterworth bandpass filter with 0.5-45 Hz. cut-off frequency, in order to eliminate artifacts and noise.

In feature extraction process, "Daubechies-4" wavelet function based seventh level "Wavelet Packet Decomposition" and "Symlet-2" wavelet function based seventh level "Wavelet Filter Bank" methods were applied. The dimensions of the extracted features were reduced via Principal Component Analysis. The feature vectors have been classified by using multilayer perceptron neural network with back propagation algorithm.

While performing mental tasks, 40 epoch training data and 10 epoch test data were collected in 30 seconds for each epoch and mental task. After that, these data split up into 1 second parts.

In total, $14(\text{sensor channel}) \times [4(\text{task}) * 40(\text{epoch}) * 31(\text{second})]$ training and $14(\text{sensor channel}) \times [4(\text{task}) * 10(\text{epoch}) * 31(\text{second})]$ test data matrices have been obtained.

The selected parameters for artificial neural network are; 1 hidden layer with 190 neurons, 0.03 learning rate, 0.2 momentum rate, performance measure "mse", training algorithm, "scaled conjugent gradient".

The training set were divided into 60% for training part, 20% for validation part, 20% for test part. In consequence of this classification, the input signals to control the brain-computer interface were obtained.

The trajectory tracking control strategy was done in the "right-left-up-down" directions hierarchically. Experiments have been performed in order to track the given reference trajectory. Offline and online classification accuracies were obtained with wavelet filter bank method for best training and test data set as 89,6%, 81.5%, respectively.

In order to increase the classification accuracy, Particle Swarm Optimization based feature selection method was applied.

As a result of this process, online classification accuracy and Kappa value were obtained as 82.94%, 0.776, respectively. The real-time recognition performance for BCI related to the trajectory tracking for 4 mental task has been achieved as %81.38.

The normalized root mean square error value for the real-time trajectory tracking via performing multi task switching, have been evaluated as 0.2818. It has been reached by using multi-mental task switching to the desired targets.

Keywords: Brain-computer interface, feature extraction, feature selection, hierarchical control, mental task classification

TEŐEKKÜR

Yüksek lisans eğitiminin boyunca yardımlarını ve tecrübelerini esirgemeyen, tez çalışmamın tamamlanmasında bana yol gösteren danışmanım Sayın Yrd.Doç.Dr.Türker Tekin ERGÜZEL'e, en içten teşekkürlerimi sunarım.

Bu günlere gelmemi sağlayan, beni her koşul altında destekleyen sevgili anne ve babama, her zaman yanımda olan ve manevi olarak hayatıma anlam katan sevgili eşime, sonsuz minnetlerimi sunarım.

Haziran 2016

Çağlar UYULAN (Mekatronik Yüksek Mühendisi)





BEYAN FORMU

Bu çalışmanın kendi tez çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi beyan ederim.



Tarih

Adı Soyadı

İmza



İÇİNDEKİLER

TABLolar.....	XVI
ŞEKİLLER.....	XVIII
KISALTMALAR.....	XXII
1.GİRİŞ.....	1
2.GENEL BİLGİLER.....	3
2.1.Elektroensefalografi Hakkında Bilgiler.....	3
2.1.1. Aksiyon potansiyeli.....	5
2.1.2. EEG sinyali üretimi.....	7
2.1.3.Beyin fonksiyonları.....	9
2.1.4. Beyin dalgaları/Ritmik aktivite.....	11
2.2.Artefakların Giderilmesine Yönelik Uygulanan Metotlar.....	14
2.3.Efektif Parametrelerin İncelenmesi.....	15
2.3.1. $\mu - \beta$ dalgası.....	15
2.3.2.Normalize edilmiş mutlak ve rölatif güç.....	15
2.3.3.ERD/ERS.....	17
2.3.4.Entropi.....	18
2.4.Öznitelik Çıkartma Metotlarının İncelenmesi	20
2.4.1.Güç spektrum yoğunluğu tahmin metotları.....	21
2.4.1.1.AAR parametreler ve AR modelleme.....	22
2.4.1.2.Doğrusal modeller.....	22
2.4.1.3.Doğrusal olmayan modelleme.....	23
2.4.1.4.Parametrik olmayan yaklaşımlar.....	24

2.4.2.Zaman-frekans domenine ilişkin öznitelik çıkartma metotlarının incelenmesi.....	25
2.4.2.1.Kısa zamanlı fourier dönüşümü	25
2.4.2.2.Sürekli dalgacık dönüşümü.....	28
2.4.2.3.Morlet dalgacık dönüşümü	29
2.4.2.4.Ayrık dalgacık dönüşümü	30
2.5.Öznitelik İndirgeme Metotlarının İncelenmesi.....	32
2.5.1.Bağımsız bileşenler analizi	32
2.5.2. Temel bileşenler analizi.....	35
2.5.2.1.Kernel PCA.....	37
2.5.3. Yaygın spasyal şablon metodu.....	37
2.5.4.Fisher formülü.....	39
2.5.5.Tekil değer ayrıştırması.....	39
2.5.6.Doğrusal ayırtaç analizi.....	40
2.6.Özniteliklerin Seçimine Yönelik Geliştirilen Algoritmaların İncelenmesi.....	40
2.6.1.Parçacık sürü optimizasyonu.....	42
2.6.2.Genetik algoritma	47
2.6.3. Karınca kolonisi optimizasyonu.....	52
2.7.Sınıflandırma Metotlarının İncelenmesi.....	55
2.7.1. Karar destek makinaları.....	56
2.7.1.1.Doğrusal ayrıştırılabilir sınıflandırma.....	57
2.7.1.2. Tamamen doğrusal ayrıştırılabilir olmayan sınıflandırma.....	58
2.7.1.3. Doğrusal olmayan sınıflandırma	58

2.7.2.Yapay sinir ađları.....	59
2.7.2.1.Yapay sinir ađlarının genel özellikleri.....	62
2.7.2.2. Perceptron modeli.....	63
2.7.2.3. Yapay sinir ađlarında öğrenme.....	64
2.7.2.4.Çok katmanlı perceptron modeli.....	65
2.7.2.5.Geri yayılım algoritması.....	66
2.7.3. K en yakın komşuluk	69
2.7.4.Sade Bayesian sınıflandırıcı	70
2.7.5.Gaussian karışım modeli	71
2.8. BCI Kontrol Stratejilerinin İncelenmesi.....	73
2.8.1.İnvazif olmayan BCI tasarımı.....	73
2.8.2.Hiyerarşik kontrol stratejisi.....	75
2.8.3.Yönel kontrol stratejisi.....	76
2.8.4. Model değerlendirme metotları.....	77
2.8.4.1.Kappa değeri.....	77
2.8.4.2.Hatanın karesinin ortalamasının karekökü.....	78
2.8.4.3.Normalize edilmiş hatanın karesinin ortalamasının karekökü.....	79
2.8.4.4.Pearson korelasyon katsayısı.....	79
3.GEREÇ VE YÖNTEM.....	80
3.1.DeneySEL Kurulum ve Verilerin Toplanması Aşaması.....	81
3.2. Ön İşleme ve Özniteliklerin Çıkartılması Aşaması.....	85
3.3.Uygulanan Öznitelik Çıkartma Metotlarının İncelenmesi.....	86
3.3.1.Symlet ana dalgacıđı tabanlı WFB.....	86

3.3.2.Dalgacık paketi dekompozisyonu	90
3.4.Öznitelik İndirgeme Aşaması.....	95
3.5.Öznitelik Seçimi Aşaması.....	96
3.6.Sınıflandırma Aşaması.....	96
3.7.Hiyerarşik Kontrol.....	99
4.BULGULAR.....	100
5.TARTIŞMA.....	122
6.SONUÇ VE ÖNERİLER.....	123
7.KAYNAKLAR.....	125
EK 1.....	133
ÖZGEÇMİŞ.....	139

TABLolar

Tablo 2.1: Ağ fonksiyonları ve nöron aktivasyon fonksiyonları.....	61
Tablo 2.2:Değerleyici tablosu.....	77
Tablo 3.1: Ayrıştırılan seviyelere ait frekans aralıkları.....	90
Tablo 4.1:Kapalı-çevrim simülasyon sonuçlarının karşılaştırılması.....	101
Tablo 4.2: Açık-çevrim simülasyon sonuçlarının karşılaştırılması.....	102
Tablo 4.3: WFB öznitelik çıkarma metodu kullanılarak elde edilen kapalı-çevrim confusion matrisi.....	103
Tablo 4.4: WFB öznitelik çıkarma metodu kullanılarak elde edilen açık-çevrim confusion matrisi.....	104
Tablo 4.5: WPD öznitelik çıkarma metodu kullanılarak elde edilen kapalı-çevrim confusion matrisi.....	106
Tablo 4.6: WFB öznitelik çıkarma metodu kullanılarak elde edilen açık-çevrim confusion matrisi.....	108
Tablo 4.7: PSO öznitelik seçimi sonuçları.....	110
Tablo 4.8: WFB öznitelik çıkartma metodu ve PSO öznitelik seçimi kullanılarak elde edilen açık-çevrim confusion matrisi.....	112
Tablo 4.9: Zihinsel görevlerin kombinasyonları için elde edilmiş gerçek-zamanlı yürünge takibi performansları.....	119



ŞEKİLLER

Şekil 2.1: Nöron yapısı.....	4
Şekil 2.2: Aksiyon potansiyeli.....	5
Şekil 2.3: Aksiyon potansiyeli işlemi.....	6
Şekil 2.4: Nöron içinde ve etrafında, farklı yerlerde tanımlanmış potansiyel üreteçleri.....	7
Şekil 2.5: EEG sinyalinin oluşum mekanizması ve senkronizasyonu.....	8
Şekil 2.6: Bilişsel fonksiyonların beyin bölgelerinde yerleşmiş haritası.....	9
Şekil 2.7: Yüksek frekans bandından, düşük frekans bandına uzanan tipik dominant beyin ritimleri.....	12
Şekil 2.8: EEG çekimlerine ait mutlak güç, rölatif güç, amplitüt asimetrisi, koherans, faz gecikmeleri bilgileri.....	16
Şekil 2.9: Genelleştirilmiş ERD/ERS ölçümü.....	18
Şekil 2.10: Entropinin olasılık dağılımlarına göre bit cinsinden ifadesi.....	20
Şekil 2.11: Öznitelik ve STFT pencerelerinin öznitelik çıkartma işlemi içerisinde gösterimi.....	27
Şekil 2.12: Kompleks morlet dalgacık fonksiyonun zaman-frekans domeninde gösterimi ve FFT cevabı.....	29
Şekil 2.13: WFB a) yeniden oluşturma b) dekompozisyon.....	31
Şekil 2.14: EEG sinyallerinin BSS konsepti ile ayrıştırılması.....	34
Şekil 2.15: PSO'ya ilişkin vektör uzayının şematik gösterimi.....	45
Şekil 2.16: Temel PSO algoritması akış şeması.....	46
Şekil 2.17: GA'nın akış diyagramı.....	48
Şekil 2.18: Rulet tekerleği seçim yöntemi.....	50
Şekil 2.19: Çaprazlama ve mutasyon operatörleri.....	51
Şekil 2.20: A.Feromon yolunu yuvadan besine takip eden karıncalar; B.Yol üzerine engel konulduğundaki durum; C. Karıncalar engel etrafında iki farklı yoldan dolanmaktadır; D.En kısa yol boyunca yeni feromon yolu düzenlenmiştir.....	53
Şekil 2.21: SVM ile yapılan ikili sınıflandırma örneği.....	57

Şekil 2.22: McCulloch&Pitts nöron modeli.....	60
Şekil 2.23: Perceptron modeli.....	64
Şekil 2.24: Çok katmanlı perceptron modeli.....	65
Şekil 2.25: 3 Katmanlı geri yayılım ağı.....	66
Şekil 2.26: KNN algoritmasına bağlı olarak yapılan sınıflandırmanın şematik gösterimi.....	70
Şekil 2.27: Invazif olmayan BCI akış diyagramı.....	74
Şekil 2.28: a) Hiyerarşik kontrol arayüzü b) Yönsel kontrol arayüzü.....	75
Şekil 2.29: Hiyerarşik strateji protokolü.....	76
Şekil 2.30: Yönsel strateji kullanılarak hedeflere erişilmesi.....	77
Şekil 3.1: BCI'da, yörünge takibi için önerilen sistem metodolojisi/akış şeması.....	80
Şekil 3.2: Emotiv EPOC standart kulaklığı.....	81
Şekil 3.3: EPOC-Simulink Sinyal Server GUL.....	82
Şekil 3.4: Emotiv EPOC Simulink Modeli.....	83
Şekil 3.5: Emotiv programına ait test ortamı ve kontrol paneli.....	84
Şekil 3.6: Her bir elektrot kanalına ait FFT spektrumlarının gösterilmesi.....	84
Şekil 3.7: 7. Seviyedeki WFB.....	87
Şekil 3.8: Symlet-2 dalgacığa ait ölçeklendirme ve ana dalgacık fonksiyonu.....	88
Şekil 3.9: Bant altı kodlama yöntemi $s(1):BETA\beta$; $s(2):ALFA\alpha$; $s(3):TETA\theta$; $s(4): DELTA\delta$	88
Şekil 3.10: Zaman formatında ifade edilen dalgacık dönüşümü katsayıları.....	89
Şekil 3.11: WPD soy ağacı yapısının şematik gösterimi.....	91
Şekil 3.12: WPT ağaç yapısı ve zaman-frekans düzleminde gösterilişi.....	92
Şekil 3.13: WPD'nin Matlab ortamındaki gösterimi.....	94
Şekil 3.14: Sınıflandırma işlemi akış şeması.....	96
Şekil 3.15: ANN mimarisi.....	97
Şekil 3.16: a) NN Pattern Recognition Toolbox'una eğitim verilerinin yüklenmesi b) ANN eğitim aşaması.....	98

Şekil 3.17: Matlab GUI'de tasarlanan BCI.....	99
Şekil 4.1: BCI Matlab&Simulink modeli.....	111
Şekil 4.2: "Alfabeyi tersten sayma", zihinsel görevine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	113
Şekil 4.3: "Sağ el hareketinin düşünülmesi", zihinsel görevine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	113
Şekil 4.4: "Sol kol hareketinin düşünülmesi", zihinsel görevine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	114
Şekil 4.5: "Matematiksel işlemlerin yapılması", zihinsel görevine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	114
Şekil 4.6: "Alfabeyi tersten sayma" ve "Sağ el hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	115
Şekil 4.7: "Alfabeyi tersten sayma" ve "Sol kol hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	115
Şekil 4.8: "Sağ el hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	116
Şekil 4.9: "Sol kol hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	116
Şekil 4.10: "Alfabeyi tersten sayma", "Sağ el hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	117
Şekil 4.11: "Alfabeyi tersten sayma", "Sol kol hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	117
Şekil 4.12: "Sağ el hareketinin düşünülmesi", "Matematiksel işlemlerin yapılması" ve "Sol kol hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	118
Şekil 4.13: "Sağ el hareketinin düşünülmesi", "Alfabeyi tersten sayma" ve "Sol kol hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	118

Şekil 4.14:"Alfabeyi tersten sayma", "Sağ el hareketinin düşünülmesi","Sol kol hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi.....	119
Şekil 4.15: Çoklu zihinsel görev değiştirilmesine dayalı gerçek-zamanlı yörünge takibi ve kontrolü işlemi.....	120
Şekil 4.16: Teste ait hedefler ve referans yollar.....	121
Şekil 4.17: Çoklu zihinsel görevlerin dinamik olarak değiştirilmesi yoluyla istenilen hedeflere ulaşılması.....	121



KISALTMALAR

EEG-Elektroensefalografi

BCI-Beyin-Bilgisayar Arayüzü

EPSP-Uyarıcı Post-Sinaptik Potansiyel

AP-Aksiyon Potansiyeli

IPSP-Engelleyici Post-Sinaptik Potansiyel

ERD-Olay İlişkili Desenkronizasyon

ERS-Olay İlişkili Senkronizasyon

SNR-Sinyal Gürültü Oranı

ADC-Analog Dijital Çevirici

ICA-Bağımsız Bileşenler Analizi

FFT-Hızlı Fourier Dönüşümü

RP- Motor Öncesi Potansiyel

BP-Bant Gücü

AR-Otoregresif

AAR-Adaptif Otoregresif

PSD-Güç Spektral Yoğunluğu

CSF-Serebro Spinal Sıvı

LDA-Doğrusal Ayırtaç Analizi

ARBF-Adaptif Radyal Tabanlı Fonksiyon

PCA-Temel Bileşen Analizi

WPD-Dalgacık Paketi Dekompozisyonu

WT- Dalgacık Dönüşümü

ARMA-Otoregresif Hareketli Ortalama

MVAR-Çok Değişkenli Otoregresif

GARCH-Genelleştirilmiş Otoregresif Koşullu Heteroskedastite

DFT-Ayrık Fourier Dönüşümü

DCT-Ayrık Cosine Dönüşümü

STFT-Kısa Zamanlı Fourier Dönüşümü

STF-Uzay-Zaman-Frekans

CWT-Sürekli Dalgacık Dönüşümü

MWT-Morlet Dalgacık Dönüşümü

DWT-Ayrık Dalgacık Dönüşümü

WFB-Dalgacık Filtre Bankası

BSS-Kör Kaynak Ayırıştırması

CSP-Yaygın Spasyal Şablon

SVD-Tekil Değer Ayırıştırması

FS-Öznitelik Seçimi

ANN-Yapay Sinir Ağları

SVM-Karar Destek Makinaları

NB-Sade Bayesian

GA-Genetik Algoritma

DE-Diferansiyel Gelişim

PSO-Parçacık Sürü Optimizasyonu

ACO-Karınca Koloni Optimizasyonu

FA-Ateş Böceği Algoritması

HMM-Gizli Markov Modeli

MLP-Çok Katmanlı Algılayıcı

FIR-Sınırlı Darbe Cevabı

QDA-Karesel Ayırtaç Analizi

SOFNN-Öz Örgütlenmeli Bulanık Sinir Ağları

RCE-Kısıtlı Coulomb Enerji

GAL-Büyü ve Öğren

KNN-K En Yakın Komşuluk

GMM-Gaussian Karışım Modeli

TPR-Doğru Pozitif Oran

FPR-Yanlış Pozitif Oran

SSVEP-Kararlı Hal Görsel Uyandırılmış Potansiyeller

SCP-Yavaş Kortikal Potansiyeller

GUI-Grafiksel Kullanıcı Arayüzü

WPT-Dalgacık Paketi Dönüşümü

RMSE-Hatanın Karesinin Ortalamasının Karekökü

NRMSE-Normalize Edilmiş Hatanın Karesinin Ortalamasının Karekökü

1.GİRİŞ

Beyin-bilgisayar arayüzü (BCI), beyin aktiviteleri ile bilgisayar arasında bağlantı kurup, herhangi bir bedensel eyleyiciye gereksinim duymaksızın mekatronik cihazların kontrol edilmesini sağlar. Gerçek-zamanlı sinyal işleme teknolojisindeki gelişmeler sayesinde, iletişim ve robot kontrolü alanlarında da BCI'nın kullanımı yaygın hale gelmiştir.

BCI sayesinde, elektroensefalograf (EEG) sinyallerinin gerçek-zamanda yüksek sınıflandırma doğruluğu gözetilerek işlenmesi mümkündür. Elektronik cihazların BCI vasıtası ile kontrol edilebilmesi için, EEG sinyallerinin uygun şekilde toplanması, işlenmesi, kıymetli bilgi taşıyan ayırt edici özniteliklerin çıkartılması ve doğru bir şekilde sınıflandırılması gerekir. Bu işlemler esnasında; düşük hesaplama yükü, yüksek sınıflandırma performansı gibi kriterleri sağlayacak efektif öznitelik çıkartma, seçme ve sınıflandırma metotlarının kullanılması oldukça önemlidir.

Bu tezde; seçilmiş zihinsel görevlere bağlı olarak kaydedilen EEG verilerinin sınıflandırılmasına odaklanılmıştır. BCI tabanlı, uyarılmış potansiyellerin, sınıflandırılma doğruluğunun artırılmasına dönük çeşitli algoritmalar araştırılmıştır. BCI tabanlı EEG sinyallerinin sınıflandırılmasına ilişkin, gerçek-zamanlı uygulamaları içeren farklı modellerin performansları da gözden geçirilmiştir. Tezin nihai amacı; efektif öznitelik çıkartma, öznitelik indirgeme, öznitelik seçme ve sınıflandırma tekniklerinin tek bir sistemde birleştirilerek, oluşturulan algoritmaya bağlı halde fiziksel çevreyi manipüle etmekte kullanılması ve yapay eyleyicilerin kontrolünün gerçekleştirilmesidir.

Bu bağlamda, EEG sinyallerinin zihinsel görev tabanlı gerçek-zamanlı sınıflandırmasını yapan BCI oluşturulacak, her bir zihinsel görev; bu arayüz üzerinde tanımlı nesnenin "sağ-sol-yukarı-aşağı" yönlerde iki boyutlu hareketini gerçekleştirecek şekilde, nesne ile ilişkilendirilecek ve bu nesnenin, zihinsel görevler icra edilerek, verili bir referans yörüngeyi takip etmesi sağlanacaktır. Bu amacın gerçekleştirilebilmesi için, kognitif nörobilim, makina öğrenmesi, veri madenciliği, sinyal işleme gibi konularda kullanılan bilgi ve metotların birleştirilerek, güçlü ve efektif bir BCI tasarlanması gerekmektedir.

Invazif olmayan BCI, kullanıcı ile simülasyon ve/veya fiziksel sistemin iletişim kurabilmesi için tasarlanmış bir arayüz programıdır. Kullanıcı, bu sayede gerçekleştirdiği zihinsel görev ile ilgili anlık geri bildirim alıp, dışsal bir mekatronik sistemi kontrol edebilmektedir.

BCI sayesinde, serebrovasküler kazadan etkilenmiş ya da diğer motor engellilikleri olan, örneğin; omurilik yaralanması geçirmiş kişiler, beyinden elde edilen sinyaller ile, elektrikli tekerlekli sandalye ya da robot kolu gibi yardımcı elemanları kontrol edebileceklerdir. BCI, EEG sinyallerini bir dışsal mekatronik cihazın kontrol girdilerine herhangi bir fiziksel hareket gerçekleştirilmeden dönüştürür. Bilişsel olarak sağlam olduğu halde, istemli kas hareketlerini yerine getiremeyen, felçli veya engelli kişilerin günlük yaşamlarını kolaylaştırmak amacıyla, hareket ettiremedikleri uzuvlarının yerine, EEG sinyalleri ile bir robot kolunu kontrol ederek, günlük ihtiyaçlarını kendilerinin görmeleri, dış dünya ile iletişime geçmeleri ve yaşam kalitelerinin iyileştirilmesi açısından büyük önem taşımaktadır.




2.GENEL BİLGİLER

Bu kısımda, insan beyni anatomisi, beyin aktivitesini ölçmek için kullanılan nörofizyolojik metotlar, EEG sinyalleri ve BCI hakkında bilgiler verilecektir. Ayrıca, BCI tasarımı için gerekli olan EEG sinyal işleme, öznelik çıkartma, indirgeme, seçme ve sınıflandırma teknikleri üzerinde odaklanılmıştır.

2.1.Elektroensefalografi Hakkında Bilgiler

İnsan beyninin sinirsel aktivitesi, prenatal gelişimin 17. ve 23. haftası aralığında başlar. İnsan beyni, yaklaşık yüz milyar sinir hücresine sahip olmakla birlikte, nöronlar arası bağlantıların sayılamayacak kadar çok olması ve yüksek plastisite kabiliyeti nedeni ile en karmaşık organdır. Nöronlar arasında gerçekleşen her bir zaman dilimine ait bilgi akışının kesin yollarının saptanıp çözümlenmesi, mevcut sinyal işleme teknolojisi ile mümkün değildir. Nöronal fonksiyonların anlaşılması, nörofizyolojik özelliklerin altında yatan mekanizmaların açıklanabilmesi, beyin anomalileri ve buna bağlı hastalıkların teşhis ve tedavisi için, beyin tarafından üretilen sinyallere ilişkin nöral aktivitenin incelenmesi gerekmektedir.

Nöral aktivite, beynin mikroskopik (post sinaptik potansiyel, aksiyon potansiyelleri), mezoskopik (yerel alan potansiyelleri, çoklu ünite aksiyon potansiyelleri) ve makroskopik (elektroensefalografik sinyaller) ölçeklerinde gerçekleşir. Her bir sinir hücresi; akson, dendrit ve hücre gövdesinden meydana gelir. Şekil 2.1'de nöronun yapısı gösterilmektedir [3].



Şekil 2.1: Nöron yapısı

Nöronlar, uyarıcılara cevap verir ve üretilen bilgiyi uzak mesafelere taşırlar. Sinir hücresi tarafından iletilen Aksiyon Potansiyeli (AP), akson başlangıç segmentinden başlayarak sinaplara doğru ilerler. Dallanan aksona sahip presinaptik nöronun, postsinaptik nöronlara doğru sinyal akışı sinapslar aracılığı ile gerçekleşir. Postsinaptik bölgeye ait dendritler, ağaç şeklinde dallanarak, gelen sinyali toplar ve diğer nöronlara aktarırlar. İnsan beynindeki her bir sinir hücresi, yaklaşık 10 000 farklı sinir hücresine dendritik kanallar aracılığı ile bağlanmıştır.


Merkezi sinir sistemi aktiviteleri, akson ve dendritlere ait sinapslar arasında iletilen sinaptik akımlarla ilişkilidir. Hücre gövdesinin membran altı, 60-70 mV aralığında negatif polariteli potansiyele sahiptir. Sinaptik aktivite gerçekleştiği zaman bu potansiyel değişmektedir. Akson boyunca hareket eden AP, uyarıcı sinaps ile sonlanırsa, bir sonraki nöronun; uyarıcı post-sinaptik potansiyel (EPSP) gerçekleşir. Eğer, iki AP, aynı akson üzerinden hareket ediyorsa, ürettikleri postsinaptik potansiyeller toplanır ve postsinaptik nöronun ait membran potansiyelinin de eşik değeri aşırsa, postsinaptik nöronun, AP üretilir.

Eğer, AP, akson engelleyici sinapsta sonlanırsa, hiperpolarizasyon durumu gerçekleşir ve bir sonraki nöronda;Engelleyici Post-Sinaptik Potansiyel (IPSP) üretilir.

2.1.1.Aksiyon potansiyeli

Sinir hücresi tarafından iletilen bilgiye "aksiyon potansiyeli" denir. Aksiyon potansiyelleri, nöron membranı boyunca gerçekleşen iyon değişimleri sayesinde meydana gelir ve akson boyunca iletilen membran potansiyelinin, geçici bir süreliğine değişimini ifade eder. Membran potansiyeli eşik değerini aşan bir uyarın (kimyasal, ışık, elektriksel, basınç, gerilme vb.) etkisi ile, depolarize (daha pozitif hale gelmek) olur ve bir tepe değerine ulaşır. Bu tepe değerinden sonra, repolarize (daha negatif hale gelmek) olarak, dinlenme potansiyelinden daha düşük bir değer alır ve sonunda normale döner. AP,5-10 milisaniye arasında gerçekleşir.


Şekil 2.2'de, Na^+ ve K^+ voltaj kapılarının sıralı bir şekilde açılmasına bağlı olarak üretilen AP görülmektedir [3].



Şekil 2.2: Aksiyon potansiyeli

AP'nin tepe noktasına ulaşması, sodyum kanallarının açılmasına bağlıdır. Sodyum iyonları, hücrenin içinde düşük, dışında yüksek miktarda bulunurlar. Uyarılan hücrelerde, membran potansiyel değişimine duyarlı olarak açılıp kapanan özel Na^+ ve K^+ kanalları mevcuttur. Sodyum kanalı açıldığında, sodyum iyonları hücre içerisine girer ve membran potansiyelini arttırmırlar.

AP'nin büyüklüğü yaklaşık olarak -60 mV ile 10 mV arasında değişmektedir. Şekil 2.3'te AP işlemi detaylı bir biçimde gösterilmektedir [2].



Şekil 2.3: Aksiyon potansiyeli işlemi

I.Dendritler uyarıldıklarında Na^+ kanalları açılır. Bu açılma, iç potansiyeli -70 mV'den-55 mV'ye yükseltmeye yeterli ise işlem devam eder.

II.AP eşik değerini geçtiği zaman ek voltaj kapılı Na^+ kanalları da açılır. Hücre içine doğru olan sodyum akışı +30 mV'ye kadar devam eder. Bu noktaya kadar olan işlem,"depolarizasyon", olarak adlandırılır.

III. Na^+ kanalları kapanır ve K^+ kanalları açılır. K^+ kanalları daha yavaş açıldığından dolayı depolarizasyon tamamlanmaya zaman bulur.


IV. K^+ kanallarının açılmasıyla, membran repolarize olmaya başlar ve dinlenme potansiyeline geri döner.

V. Repolarizasyon işlemi, membran potansiyeli -90 mV'ye düşünceye kadar devam eder. Dinlenme potansiyelinin altındaki bir potansiyel değerine düşme işlemi,"hiperpolarizasyon", olarak adlandırılır. Hiperpolarizasyon, nöronun yeni bir uyarın almasını engeller.

VI.Hiperpolarizasyon işleminden sonra, $\frac{Na^+}{K^+}$ pompası enerji harcayarak,zarı, dinlenme durumuna (-70 mV) geri getirir.

2.1.2. EEG sinyali üretimi


Sinapsların aktivasyonu sonucunda, aktivite merkezi etrafında ölçümlenebilen, yerel potansiyel gradyanlar meydana gelir. AP'lerin kısa (1-2 ms) sürmesine karşın, postsinaptik potansiyellerin, potansiyel değişimleri uzun sürelidir (10-40 ms). Tek bir nörona ait sinaptik potansiyellerin toplamı Şekil 2.4'te gösterilmiştir.



Şekil 2.4: Nöron içinde ve etrafında, farklı yerlerde tanımlanmış potansiyel üreteçleri

EEG oluşumuna en çok katkıda bulunan üreteç, toplanmış postsinaptik potansiyellerdir. Dendritler etrafında gerçekleşen postsinaptik potansiyeller zamanla yavaş değişen karakteristiklere sahip olduklarından dolayı, süperpozisyon halinde indüklenip, senkron hale gelerek EEG ölçümünde görünüm kazanırlar. EEG sinyalleri; gövdeleri serebral korteksin 5. ve 6. tabakalarında bulunan ve kafa yüzeyine dik yerleşimli geniş dendritik ağaca sahip olan piramidal nöronlarda gerçekleşen, postsinaptik potansiyeller sonucu, ekstraselüler alanda ortaya çıkan elektrik akımlarıdır. Yerel alan potansiyelleri tarafından görülemeyen geniş nöral ağların aktivitelerini yansıtır.

Kafatası ve derisi, sinyali zayıflattığı için, ancak çok sayıda nöronun senkron aktivitesi, görünür sinyali oluşturur. Şekil 2.5'te EEG sinyali oluşum mekanizması ve senkronizasyonu gösterilmiştir.



Şekil 2.1: Nöron yapısı

Nöronlar, uyarıcılara cevap verir ve üretilen bilgiyi uzak mesafelere taşırlar. Sinir hücresi tarafından iletilen Aksiyon Potansiyeli (AP), akson başlangıç segmentinden başlayarak sinaplara doğru ilerler. Dallanan aksona sahip presinaptik nöronun, postsinaptik nöronlara doğru sinyal akışı sinapslar aracılığı ile gerçekleşir. Postsinaptik bölgeye ait dendritler, ağaç şeklinde dallanarak, gelen sinyali toplar ve diğer nöronlara aktarırlar. İnsan beynindeki her bir sinir hücresi, yaklaşık 10 000 farklı sinir hücresine dendritik kanallar aracılığı ile bağlanmıştır.


Merkezi sinir sistemi aktiviteleri, akson ve dendritlere ait sinapslar arasında iletilen sinaptik akımlarla ilişkilidir. Hücre gövdesinin membran altı, 60-70 mV aralığında negatif polariteli potansiyele sahiptir. Sinaptik aktivite gerçekleştiği zaman bu potansiyel değişmektedir. Akson boyunca hareket eden AP, uyarıcı sinaps ile sonlanırsa, bir sonraki nöronun; uyarıcı post-sinaptik potansiyel (EPSP) gerçekleşir. Eğer, iki AP, aynı akson üzerinden hareket ediyorsa, ürettikleri postsinaptik potansiyeller toplanır ve postsinaptik nöronun ait membran potansiyelinin de eşik değeri aşırsa, postsinaptik nöronun, AP üretilir.

Eğer, AP, akson engelleyici sinapsta sonlanırsa, hiperpolarizasyon durumu gerçekleşir ve bir sonraki nöronda;Engelleyici Post-Sinaptik Potansiyel (IPSP) üretilir.

2.1.1.Aksiyon potansiyeli

Sinir hücresi tarafından iletilen bilgiye "aksiyon potansiyeli" denir. Aksiyon potansiyelleri, nöron membranı boyunca gerçekleşen iyon değişimleri sayesinde meydana gelir ve akson boyunca iletilen membran potansiyelinin, geçici bir süreliğine değişimini ifade eder. Membran potansiyeli eşik değerini aşan bir uyarın (kimyasal, ışık, elektriksel, basınç, gerilme vb.) etkisi ile, depolarize (daha pozitif hale gelmek) olur ve bir tepe değerine ulaşır. Bu tepe değerinden sonra, repolarize (daha negatif hale gelmek) olarak, dinlenme potansiyelinden daha düşük bir değer alır ve sonunda normale döner. AP,5-10 milisaniye arasında gerçekleşir.


Şekil 2.2'de, Na^+ ve K^+ voltaj kapılarının sıralı bir şekilde açılmasına bağlı olarak üretilen AP görülmektedir [3].



Şekil 2.2: Aksiyon potansiyeli

AP'nin tepe noktasına ulaşması, sodyum kanallarının açılmasına bağlıdır. Sodyum iyonları, hücrenin içinde düşük, dışında yüksek miktarda bulunurlar. Uyarılan hücrelerde, membran potansiyel değişimine duyarlı olarak açılıp kapanan özel Na^+ ve K^+ kanalları mevcuttur. Sodyum kanalı açıldığında, sodyum iyonları hücre içerisine girer ve membran potansiyelini artırırlar.

AP'nin büyüklüğü yaklaşık olarak -60 mV ile 10 mV arasında değişmektedir. Şekil 2.3'te AP işlemi detaylı bir biçimde gösterilmektedir [2].



Şekil 2.3: Aksiyon potansiyeli işlemi

I. Dendritler uyarıldıklarında Na^+ kanalları açılır. Bu açılma, iç potansiyeli -70 mV'den -55 mV'ye yükseltmeye yeterli ise işlem devam eder.

II. AP eşik değerini geçtiği zaman ek voltaj kapılı Na^+ kanalları da açılır. Hücre içine doğru olan sodyum akışı +30 mV'ye kadar devam eder. Bu noktaya kadar olan işlem, "depolarizasyon", olarak adlandırılır.

III. Na^+ kanalları kapanır ve K^+ kanalları açılır. K^+ kanalları daha yavaş açıldığından dolayı depolarizasyon tamamlanmaya zaman bulur.

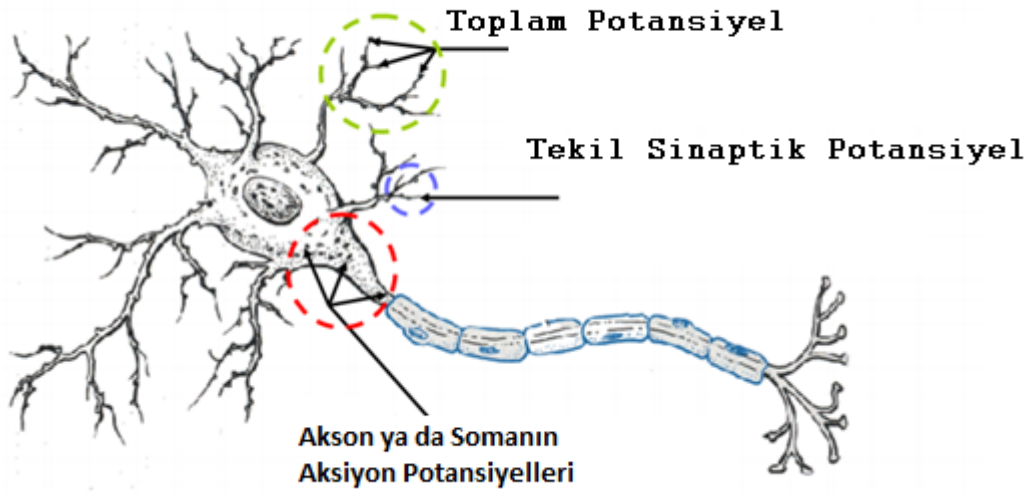
IV. K^+ kanallarının açılmasıyla, membran repolarize olmaya başlar ve dinlenme potansiyeline geri döner.

V. Repolarizasyon işlemi, membran potansiyeli -90 mV'ye düşüncüye kadar devam eder. Dinlenme potansiyelinin altındaki bir potansiyel değerine düşme işlemi, "hiperpolarizasyon", olarak adlandırılır. Hiperpolarizasyon, nöronun yeni bir uyarı almasını engeller.

VI.Hiperpolarizasyon işleminden sonra, $\frac{Na^+}{K^+}$ pompası enerji harcayarak,zarı, dinlenme durumuna (-70 mV) geri getirir.

2.1.2. EEG sinyali üretimi

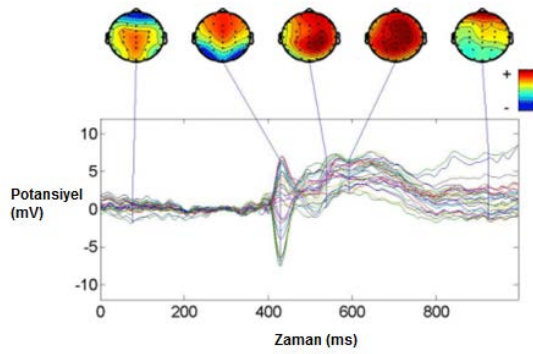

Sinapsların aktivasyonu sonucunda, aktivite merkezi etrafında ölçümlenebilen, yerel potansiyel gradyanlar meydana gelir. AP'lerin kısa (1-2 ms) sürmesine karşın, postsinaptik potansiyellerin, potansiyel değişimleri uzun sürelidir (10-40 ms). Tek bir nörona ait sinaptik potansiyellerin toplamı Şekil 2.4'te gösterilmiştir.



Şekil 2.4: Nöron içinde ve etrafında, farklı yerlerde tanımlanmış potansiyel üreteçleri

EEG oluşumuna en çok katkıda bulunan üreteç, toplanmış postsinaptik potansiyellerdir. Dendritler etrafında gerçekleşen postsinaptik potansiyeller zamanla yavaş değişen karakteristiklere sahip olduklarından dolayı, süperpozisyon halinde indüklenip, senkron hale gelerek EEG ölçümünde görünüm kazanırlar. EEG sinyalleri; gövdeleri serebral korteksin 5. ve 6. tabakalarında bulunan ve kafa yüzeyine dik yerleşimli geniş dendritik ağaca sahip olan piramidal nöronlarda gerçekleşen, postsinaptik potansiyeller sonucu, ekstraselüler alanda ortaya çıkan elektrik akımlarıdır. Yerel alan potansiyelleri tarafından görülemeyen geniş nöral ağların aktivitelerini yansıtır.

Kafatası ve derisi, sinyali zayıflattığı için, ancak çok sayıda nöronun senkron aktivitesi, görünür sinyali oluşturur. Şekil 2.5'te EEG sinyali oluşum mekanizması ve senkronizasyonu gösterilmiştir.




Şekil 2.5: EEG sinyalinin oluşum mekanizması ve senkronizasyonu

EEG amplitütleri, sadece nöronal aktivasyonların toplamını ifade etmez, aynı zamanda global nöral ağın senkronizasyonunu gösterir. Kafatası yüzeyinden kaydedilen EEG sinyalleri, çok sayıda nöronun sözde-senkron ateşlenmesi sonucu üretilen geniş dendritik akımlar tarafından ortaya çıkar. Spontan EEG salınımları, nöral dokuların canlılığını sürdürmesi ile ilgili faaliyetleri yansıtır, uyku-uyanıklık döngüsü, beyin gelişimi ve zihinsel aktivite düzeyi hakkında bilgi verir. Kognitif bozukluklarla seyreden hastalıklarda, belirgin değişim gösterirler. Elektrotlar, bireysel aksiyon potansiyellerini ölçmede yetersizdirler, ancak farklı nöronlardan kaynaklanan, çok sayıda aksiyon potansiyellerinin, eş-zamanlı olarak üretilmesi sonucu oluşan elektrik akımlarını kaydederler.

2.1.3.Beyin fonksiyonları

Benzer fonksiyonlara sahip nöronlar birbirleri ile bağlantı kurarlar. Bu nöronal birleşmeler, makroskopik boyutlardan mikroskopik boyutlara doğru daha da özelleşir ve kompleks hale gelir. Örneğin, serebral yarımkürenin arkasında konumlanmış oksipital lobun bir parçası olan görsel kortekse ait bazı nöronal birleşmeler, renk kodlamasında özelleşmişken, bazıları da, hareket ve şekil konusunda uzmanlaşmıştır. Çoklu özelleşmiş nöronal gruplar arasında gerçekleşen, bilgi işleme ve etkileşimleri sonucunda açığa çıkan duruma; "kognisyon" adı verilir. Şekil 2.6'da beynin farklı bölgelerine ait bilişsel fonksiyonların, lob seviyesinde yerleşmiş haritası gösterilmektedir.



Şekil 2.6: Bilişsel fonksiyonların beyin bölgelerinde yerleşmiş haritası

Karmaşık işlevlerin, beyinle olan ilişkilerinin açıklığa kavuşturulması, onlara ait saf hallerin bilinmesi ile gerçekleşir. Beyin işlevselliğini anlamak, bütünsellik prensibi sayesinde mümkün olmaktadır. Beyinde bütünsellik, basitten karmaşığa doğrudur. Her beyin bölgesi, diğer beyin bölgeleriyle birlikte çalışır. Beyindeki bütünsellikte, sol ve sağ yarımkürelerin önemli işlevleri vardır. Beyin, diğer sinir sistemi bölümleriyle, gövdeyle ve aynı zamanda dış dünya ile birlikte çalışır. Beynin her bir yarısında bulunan 4'er lobun her birinde, temel bir beyin işlevine ait alan bulunmaktadır. Beyine dışarıdan ilk giriş alanları his, görme, işitme iken, beyinden son çıkış noktası da hareket alanıdır. Bu alanlar, temel beyin alanları olarak adlandırılırlar. Beyinde meydana gelebilecek tüm işlevler bu döngü içindedir.

Temel beyin alanları dışında kalan alanlar, yapıları giderek karmaşıklaşan ve hücre tiplerinin sayısı giderek artan alanlar olmakla beraber, kendi içlerinde iki ana bölüme ayrılırlar.

Birinci grup, her bir temel beyin alanının hemen yanında ya da etrafında bulunan ve o temel alanın işlevlerini bir üst düzeye çıkaran alanlardan oluşan gruptur. Bu alanlar da her biri, ayrı bir lobta olmak üzere 4 tanedir. Bunlar sadece kendileriyle ilgili temel beyin alanından yönelen girdiyi işler ve onu daha karmaşık hale getirir.

Örneğin; hareketle ilgili lobta bulunan; hareketin beceriyle harmanlanmasını, his uyarıları ile ilgili olan; bu türden uyarıların niteliklerinin arttırılmasını, işitmeye ilgili olan; işitilenin anlaşılmasını, görmeyle ilgili olan ise, görülenin özelliklerinin detaylandırılmasını sağlar.

İkinci grup, sosyal ortamlarda, neyin, nerede ve ne zaman yapılacağına karar vererek davranmayı sağlayan daha gelişmiş ve karmaşık yapıda beyin alanlarından oluşur. Bu alanlar, sağ ve sol lobta ikiye adet bulunurlar. Önde bulunan yapı, düşünce ve duygu kontrolünü sağlarken, arkada bulunan yapı da karmaşık görsel-mekansal karar ve kontrol merkezidir. Bu alanda, işitmeye, görmeyle ve dokunmayla ilgili uyarılar sentezlenir ve başka uyarılarıyla bütünleştirilir. Bu alanlar, aynı zamanda okuma ve yazma gibi karmaşık işlevlerin de merkezini teşkil etmektedir. Beyin yarımküreleri arasında "korpus kallozum" yoluyla sağlanan koordinasyona ek olarak, sol ve sağ yarımkürelerin içinde bulunan alanlar, kendi aralarında bağlantılara sahiptir. Bu bağlantılar, lif demetleri vasıtasıyla gerçekleştirilir. Lif demetleri yoluyla sağlanan bağlantılar, önce lob içi alanları birleştirir ve iki yönlüdür. Basitten karmaşığa doğru olan lif demetleri, her aşamada, bir üst karmaşıklıkta beyin alanını devreye alarak kognitif yapılanmayı, karmaşıktan basite doğru olan lif demetleri ise; her aşamada düşünme ve davranışın kontrolünü sağlar. Lob içi bağlantılar ve bunların çalışma biçimleri aşağıda verilmektedir [4].

Frontal Lob: Frontal lob içinde, basitten karmaşığa; motor, premotor ve prefrontal, karmaşıktan basite ise, bunun tersi yönünde bağlantılar vardır. Bunlar sayesinde, basit ve niteliksiz bir hareket, nitelikli hale gelir. Daha sonra, sosyal içerik kazanır ve duygularla ilişkili bir hal alır. Uzun süreli hafıza ve planlamaya olan etkisi büyüktür.


Parietal Lob:Somatik uyarıları analiz eden lobtur. Çevreden ve gövdemizden gelen duyu uyarılarının kalite ve çeşitleri konusunda bilgi sağlar. Birinci ve ikinci dereceden bağlantı alanları sayesinde, çevresel ve gövdesel duyu uyarıları nitelik kazanır. Uyarının ne olduğu, özellikleri ve görsel-işitsel uyarımlarla bütünleşmesi sağlanır. Sağ taraftaki parietal lob, daha çok mekan tanıma ve yerleşim bilgisi, gövde haritası gibi görsel-mekansal analizler yaparken, sol taraftaki ise, daha çok dil ile ilişkili analizler yapar.

Temporal Lob:Temporal lob işitsel, kokusal, tadsal uyarıları işler, gövdesel duyu işlevi açısından önemlidir. Epizodik ve spasyal hafıza fonksiyonlarında ve aynı zamanda kısa dönemli hafızanın uzun dönemli hafızaya aktarılmasında etkin görev üstlenir. Sol yarımküredeki temporal lob, kelimesel sesleri, sağdaki ise kelimesel olmayan sesleri analiz eder. İkinci derecede bağlantı alanları, dış yüzde oksipital lobla bağlantılı olarak, görsel bellekle ve iç yüzde ise; limbik sistemle bağlantılı olarak, emosyonlarla ilişkilidir. Yüz tanıma işlemi de bu lobda gerçekleştirilir.

Oksipital Lob:Görme ve görsel analiz lobudur. Oksipital lob içinde, temel görme alanının bilgi aktardığı en az dört ayrı türden görsel analiz yapan yardımcı alan vardır. Bu alanlar, nesne tanıma, derinlik algısı oluşturma, spasyal frekans, renk ve görsel hareket algıları ile bağlantılıdır.

2.1.4. Beyin dalgaları/Ritmik aktivite

Frekans aralıklarına göre değişim gösteren beş temel beyin dalgası vardır. Bu frekans bantları alçak frekanstan, yüksek frekansa doğru, sırasıyla; alfa (α), teta (θ), beta (β), delta (δ) ve gama (γ) olarak adlandırılır. EEG ritmik aktivite tipleri ve onlara ilişkin frekans bantları Şekil 2.7'de verilmiştir [2].



Şekil 2.7: Yüksek frekans bandından, düşük frekans bandına uzanan tipik dominant beyin ritimleri
Delta dalgaları, 0.5-4 Hz. aralığındadır ve yüksek amplitüde sahiptir. Derin uyku ile irtibatlandırılır. Boyun kasları derinin yüzeyine yakın olduğundan ve büyük sinyaller ürettiği için, genellikle delta dalgaları ile karıştırılır.

Teta dalgaları, 4-7.5 Hz. aralığında değişmektedir. Hipokampal alanda konumlanmıştır ve talamik kökenli olduğuna dair bulgular vardır. Teta dalgaları, bilinçlilik halinden uykulama haline geçiş esnasında ortaya çıkarlar. Bilinç dışı alana ve derin meditasyon haline işaret ederler. Yapılan araştırmalar sonucunda, teta dalgalarının, neokorteksteki EEG sinyallerine ait eş zamanlılığın bozulması esnasında gerçekleştiği gösterilmiştir. Buna karşın, Vanderwolf [48], teta dalgalarının, motor eylemler ile olan güçlü korelasyonundan dolayı, sensorimotor işlemlerle bağlantılı olduğunu ileri sürmüştür. Amplitütleri genellikle 20 μ V'tan yüksektir.

Alfa dalgaları, μ -ritmi, 8-13 Hz.'lik frekans bandında faaliyet gösterirler. Kafanın arka yarısında ve oksipital bölgede oluşurlar. Arka lobların bütününde tespit edilmeleri muhtemeldir. Genellikle, yuvarlak ya da sinüzoidal şekle sahiptirler. Alfa dalgaları, konsantrasyon ya da dikkat olmaksızın gerçekleşen sakin farkındalığa işaret ederler.

Genelde, gözler kapalı iken meydana gelirler, ancak, aşına olunmayan bir ses duyumu, gerginlik ya da zihinsel konsantrasyon durumunda ortadan kaybolurlar. Benzer bir ritim olan μ -ritmi, motor korteks üzerinde, genellikle hareket düşünüldüğü esnada gözlemlenir. BCI uygulamalarında oldukça önemli bir özneliktir. α ve μ ritimleri, üst üste binmelerine rağmen, konumlanışları itibarı ile birbirlerinden ayrılırlar. 10 Hz.'lik görsel alfa ritmi aktivitesi, görsel korteks üzerinde odaklanmış iken, μ ritmi de; somatosensori korteks üzerinde odaklanmıştır. μ ritmikortikal bölgelerde meydana geldiğinden dolayı, motor çıktı kanalları ile doğrudan bağlantılı olsa da, hareket imgelemi; μ ve β ritimlerinde düşüşe sebep olur. Bu fenomen; Olay İlişkili Desenkronizasyon (ERD) olarak adlandırılır [45,46,47] ve amplitütleri 30 – 50 μ V aralığındadır.

Beta dalgaları, 14-30 Hz.'lik frekans bandında gerçekleşir. Aktif düşünme, dikkat, odaklanma, soyut problem çözme durumlarında gözlemlenir. Yüksek seviyeli beta dalgası ise, panik ve gerginlik halinde oluşmaktadır. Ritmik beta aktivitesine, frontal ve merkezi bölgelerde rastlanır. Beta ritmi, normalde 30 μ V'luk amplitüte sahiptir, ancak, 5-30 μ V aralığında daha düşük voltaj değerleri de alabilir.

Gama dalgaları, 30-100 Hz. aralığında değişim göstermektedir. Gama dalgalarının fonksiyonel rolü henüz tam anlamıyla bilinmemektedir. Bu ritmik aktivitenin, bilinçli algılama, özellikle de, "bağlantı problemi" ile ilişkili olduğu düşünülmektedir. Yüksek EEG frekansına, genellikle serebral kan akışının yüksek olduğu bölgelerde rastlanmaktadır. Gama dalgasının; Olay İlişkili Senkronizasyon'un (ERS) indikatörü olduğu ispatlanmıştır. Sol-sağ parmak, sağ ayak başparmakları ve dil hareketlerine ait yerleri göstermekte kullanılabilir.

Yapılan araştırmalar sonucunda, yüksek genlikli sinyalin, yüksek kognitif işlemleri değil, yüksek senkronizasyonu yansıttığı, düşük genlikli sinyalin ise; daha yerel senkronizasyonun göstergesi olduğu görülmüştür. Beta ve gama aktivitelerinde, ara nöronlar önemli rol oynar. Daha düşük frekanslarda ise, uyarıcı bağlantıların oluşturduğu ve daha uzun mesafede sinyal iletimine dayanan büyük ölçekli ağların senkronizasyonu belirgindir. Psikiyatrik hastalıkların nörofizyolojisi ve patofizyolojisi keskin hatlarla tanımlanmadığından, spontan EEG analizinde gerçekleştirilen tanılama yaklaşımı, çoğunlukla korelatiftir.

2.2.Artefakların Giderilmesine Yönelik Uygulanan Metotlar

Beyin üzerinden kaydedilen elektriksel dalga formlarına ait elektrik potansiyellerinin bazıları, beyin tarafından üretilmemektedir. Bu elektrik potansiyellerinin kaynakları; genellikle göz kırpma, göz hareketleri, kalp ve kasların kasılma aktiviteleri şeklindedir. Aynı zamanda, EEG kayıt cihazına ait gürültülerin etkisi de göz ardı edilemez.

Bu dalga formlarının girişimleri "artefak" olarak adlandırılır. Artefaklar sıklıkla BCI üzerinde yanlış sınıflandırmalara sebep olurlar. Pratikte,gerçek-zamanlı efektif bir BCI geliştirebilmek için, bu tür artefakların tespit edilip giderilmesi gereklidir. Sinyal işleminin amacı, Sinyal Gürültü Oranı'nı (SNR) maksimize etmektir. EEG sinyalleri çok fazla gürültü kaynağı ile karşılaştığından, SNR'nin sinyal ön-işleme safhasında maksimize edilmesi gereklidir.

Nöral olmayan (göz hareketleri, kas aktiviteleri, 50 Hz.'lik güç kaynağı gürültüsü) ve nöral olan (kontrol amacı ile kullanılmayan diğer EEG öznitelikleri), iki tür gürültü kaynağı mevcuttur. 0.3 Hz. civarında kesim frekansına sahip olan yüksek geçiren filtreler, nefes alma gibi çok düşük frekans bileşenlerine sahip olan bozucu etkilerin kaldırılmasında kullanılırlar. Diğer yandan, yüksek frekanslı gürültüye sahip bileşenler de, kesim frekansı 40 Hz. civarında olan alçak geçiren filtreler kullanılarak ortadan kaldırılırlar. Bu sayede, göz kırpma hareketi ve kas hareketlerine ilişkin artefaklar da giderilmiş olur [8].

Ham EEG sinyalleri, mikrovolt seviyesinde büyüklüğe sahip ve 300 Hz. değerine kadar ulaşabilen frekans bileşenlerinden oluşmuştur. Efektif bilginin elde edilebilmesi için sinyallerin, Analog Dijital Çevirici (ADC) ve filtreleme işlemlerinden önce yükseltip gürültünün bastırılması gereklidir. 0.5 Hz.'lik kesim frekansından düşük frekanslara sahip yüksek geçiren filtreler, nefes almadan kaynaklanan düşük frekans bileşenlerinin giderilmesinde kullanılır. Diğer taraftan yüksek frekanslı gürültü de, yaklaşık 50-70 Hz.'lik kesim frekansına sahip alçak geçiren filtre kullanılarak azaltılır. 50 Hz'lik Notch filtresi, 50 Hz.'lik güç kaynağı gürültüsünün ortadan kaldırılmasını sağlar. Örnekleme frekansı, EEG sistemleri tarafından kullanılan bant genişliğinin iki katından daha az olmalıdır. Genellikle kullanılan örnekleme frekansları, saniyede 100,250,500, 1000 ve 2000 örnekleme aralığında değişmektedir [2].

Bağımsız Bileşenler Analizi (ICA), ne kaynak sinyali ne de referans sinyaline ait özelliklere erişilmesini gerektirmediğinden dolayı, artefakların giderilmesinde oldukça etkili bir yöntemdir. ICA, artefakların giderilmesinde ve sinyalin yeniden yapılandırılmasında standart metotlardan daha iyi performans göstermektedir [48].

2.3.Efektif Parametrelerin İncelenmesi

EEG sinyalleri, nöral aktivitenin işaretleridir. Sinyaller; zaman,frekans,spasyal domenlerde analiz edilirler. Spasyal domendeki beyin aktivitesi haritası olan EEG topografilerinin görselleştirilmeleri mümkündür. EEG sinyallerinin işlenmesine yönelik olarak, birçok farklı türden algoritma geliştirilmiştir. Beyin sinyallerinin kaynağını konumlandırmak için, elektromanyetik dalga yayılımının ve ölçülen sinyallerdeki efektif parametrelere ait bilgilerin iyi bir şekilde tespit edilmesi gereklidir. Kaynaklar, manyetik dipol olarak düşünülebilir ve bu doğrultuda tersine problem çözümü uygulanabilir, ya da ayrılmış akım kaynağı olarak da modellenebilir. EEG sinyalleri, birçok farklı parametre tarafından etkilenen, oldukça komplike ve duyarlı biyosinyaller arasındadır. EEG tabanlı BCI'lar; yeniden üretilebilir elektrofizyolojik sinyallerin işlenmesine bağlıdır. Farklı türdeki bu elektrofizyolojik özellikler, zihinsel görevlerin kontrol ve kumanda işaretlerine dönüştürülmesinde kullanılırlar.

Bu bölümde, EEG sinyallerinin sınıflandırılmasında dikkate alınan bazı etkin parametreler ve onların elektrofizyolojik temelleri üzerinde durulacaktır.

2.3.1. μ – β dalgası

En temel parametrelerden birisi, μ dalgası büyüklüğüdür. μ dalgası, motor aktivitelere ilişkin EEG dalgasıdır. μ dalgası, α dalgası ile aynı temel frekansa sahiptir. μ ve β frekans bandındaki dalgaların büyüklüklerinin değişimlerinin araştırılmasına yönelik kullanılan zihinsel görev tabanlı sınıflandırma algoritmaları oldukça yaygındır.

2.3.2.Normalize edilmiş mutlak ve rölatif güç

Güç hesaplamalarında, artefaksız EEG trasesinin Hızlı Fourier Dönüşümü (FFT) alınır ve mutlak değerinin karesi ile, her frekans bandı için ortalama güç değeri hesaplanır. Rölatif güç ise, bir frekans bandına ait mutlak güç değerlerinin tüm frekans bandına oranlanması ile elde edilir.

$P(s, f)$, s elektrodunun, f frekans bandındaki gücü ise, rölatif güç aşağıdaki gibi hesaplanır:


$$R(s, f) = \frac{P(s, f)}{\sum_f P_{s, f}} \quad (2.1)$$

Bununla birlikte, birebir kanallar arasında yapılan, standart sapma, genlik, faz karşılaştırması ve koherans hesaplamaları da vardır. Z-skor değerleri normatif veri tabanı kullanılarak elde edilir. Beyin bölgeleri boyunca mutlak ve rölatif güçlerin hesaplanmasına; "spasyal normalizasyon" adı verilir. Spasyal normalizasyon için z-skor değerleri, aşağıdaki formüle göre elde edilir.

$$X = \frac{(x - \bar{x})}{\text{std}(x)} \quad (2.2)$$

Burada; \bar{x} , tüm elektrot değerleri içintek frekans bandındaki ortalama ve $\text{std}(x)$, standart sapma değerleridir. Normalize edilmiş mutlak ve rölatif güç ölçümleri arasındaki ilişki aşağıdaki formüle göre karakterize edilir [53].

$$Z(s, f) = A_{\text{norm}}(s, f) + R_{\text{norm}}(s, f) \quad (2.3)$$



Şekil 2.8: EEG çekimlerine ait mutlak güç, rölatif güç, amplitüt asimetrisi, koherans, faz gecikmeleri bilgileri

2.3.3.ERD/ERS

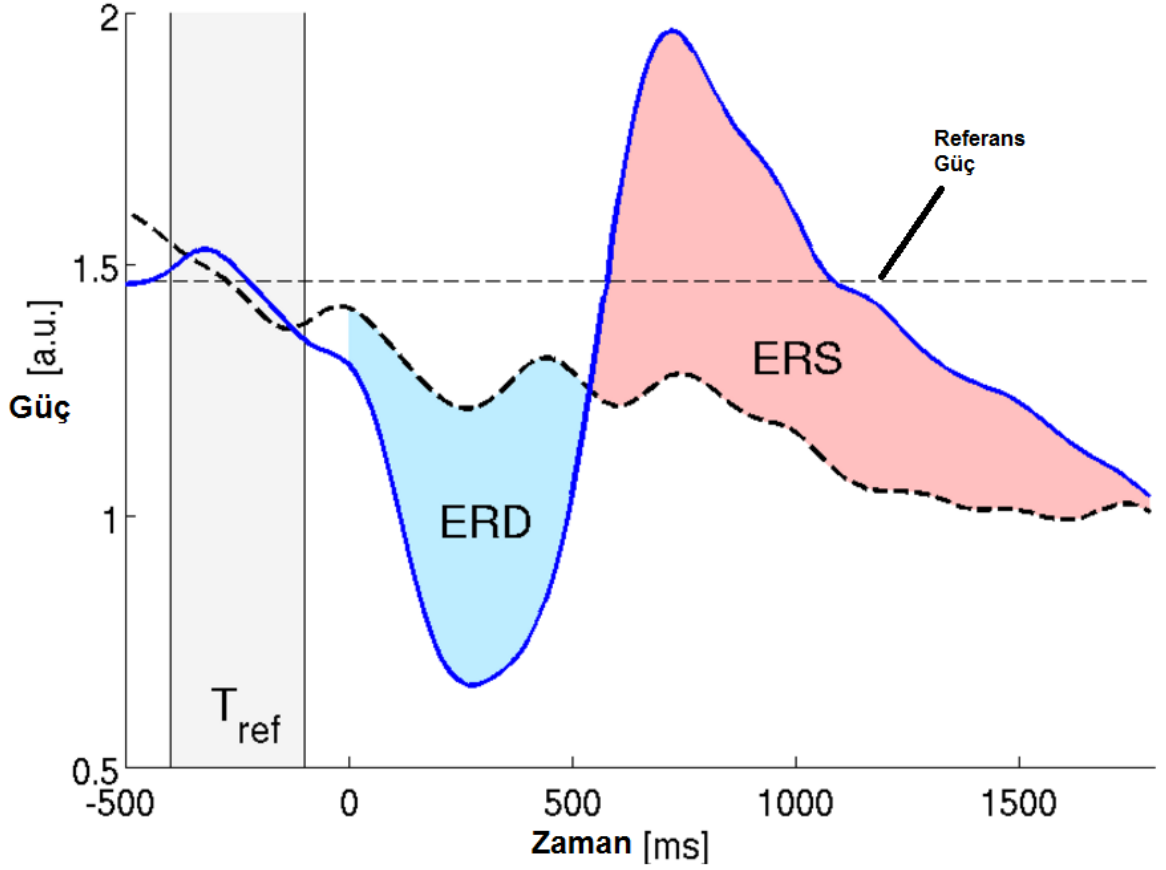
Frekans bandı, 8-12 Hz. aralığında olan μ ritmi; somatosensöri korteks üzerinden motor çıktısı ya da duyuşal girdi işleme yapmayan uyanık deneklerde ölçülebilir. Güncel ritim, spasyal yer ve karakteristik frekanslarına ayrıştırılabilen bant aralığındaki frekans çeşitliliğinden meydana gelir. Bu ritimler, 18-26 Hz. aralığındaki β ritmi ile korelatif bir ilişki içerisindedir. Kortikal alanlardaki, örneğin sensorimotor bölgede aktif hale gelen motor eylemi ya da eylemin düşünsel imgelemi, μ ve β ritimlerinin frekans yoğunluğunun düşmesine yol açar. Bu amplitüt düşüşü, ERD olarak tanımlanır.

Bunun tersi olan ERS ise; motor eylemden ya da eylemindüşünsel imgeleminden sonraki rahatlama durumunda, μ ve β ritimlerine ait frekans yoğunluğundaki artışın meydana gelmesi şeklinde tanımlanır. Spesifik frekans bandının ne kadar değiştiği hakkında açık bir nicelleştirme elde edebilmek için, referans güce ihtiyaç vardır.

ERD/ERS, α bandındaki güç cinsinden aşağıdaki formüle göre ölçülür.

$$\text{ERD/ERS} = \frac{P(f,n) - P_{\text{ref}}(f)}{P_{\text{ref}}(f)} \quad (2.4)$$

Burada, $P(f, n)$, ortalama güç haritasının verili zaman-frekans noktasındaki sinyal gücünün değeridir. $P_{\text{ref}}(f)$; f frekansı için hesaplanan referans zamanı boyunca etkiyen ortalama güçtür. Gerçek hareket yapılmadan 1-2 saniye önce, α bandındaki desenkronizasyon görülür hale gelir. Buna da, Motor Öncesi Potansiyel (RP) adı verilir. Genelleştirilmiş ERD/ERS'ye ait olay-ilişkili dinamiğin, rölatif sapma ölçümü, Şekil 2.9'da verilmiştir [52].



Şekil 2.9: Genelleştirilmiş ERD/ERS ölçümü

ERS/ERD'ye ait lokasyon ve frekans aralıkları, denekler arasında değişiklik arz etmektedir. ERD, motor davranışın üretilmesi, kognitif ya da sensoriyel bilgi işleme sonucu aktive edilmiş kortikal bölgelerin elektrofizyolojik korelasyonları açısından yorumlanabilir.

2.3.4. Entropi

Enformasyon teorisi açısından entropi; belirsizliğin, herhangi bir kaynak verisinde saklanan bilgiyi ifade edebilmek için bir ölçü olarak kullanılmasıdır. Entropi kavramı, sistemin makro durumun tanımlanmasında gereken bilgi miktarının nicelleştirilmesi amacıyla üretilmiştir ve sembollerin sekansına ait bilgi içeriğini, herhangi bir olasılık modelinden bağımsız olarak yansıtan "Kolmogorov karmaşıklığı" kavramı ile yakından ilişkilidir. Kolmogorov karmaşıklığı; bir objeyi tanımlamak için gereksinim duyulan hesaplama kaynaklarının ölçüsüdür.

Bilgi entropisini bir örnekle açıklayacak olursak; A, B, C, D harflerine ilişkin sembolik çıktılar veren iki farklı makine düşünelim. İlk makine, sembolleri eşit olasılık dağılımı ile üretiyor olsun, ikinci makine ise; sembolleri %50 olasılıkla A , %12,5 olasılıkla B , %12,5 olasılıkla C ve %25 olasılıkla D çıktısı verecek şekilde üretiyor olsun.

Bu durumda, hangi makinenin daha fazla bilgi üreteceği sorusu sorulabilir. Bu soru, "makinelere çıkan bir sonraki harfin tahmin edilmesi istenildiğinde, her makine için en az kaç "evet" ya da "hayır" sorusu sorulması gerekirdi?" şeklinde ifade edilecek olursa, birinci makineden çıkacak bir sonraki sembolü kestirebilmek için, sembol başına iki soru sormamız gerekirken, ikinci makineden çıkan bir sonraki sembolün bilinebilmesi için gerekli ortalama soru sayısını aşağıdaki formül ile hesaplayabiliriz:

$$p_A \times 1 + p_B \times 3 + p_C \times 3 + p_D \times 2 \quad (2.5)$$


p_i : i . sembole ait olasılık

N : ortalama soru sayısı

Bu hesaplama sonucunda, ortalama 1.75 soru sorulması gereklidir. Bu durumda ikinci makinenin daha az bilgi ürettiği sonucuna ulaşılır. Zira, çıktısındaki belirsizlik, ilk makineye göre daha düşüktür. Burada bir bilgi kaynağı, "Markoff süreci" olarak temsil edildiğinde, böyle bir süreçte ne kadar bilginin üretildiği, hatta hangi oranda üretildiğini ölçmek için kullanılacak bir ölçü biriminin var olup olmadığı sorusu sorulmuştur. Claude Shannon, herhangi bir rastsal değişken üzerindeki bu ortalama belirsizlik ölçüsüne entropi adını vermiştir [36]. $p_1, p_2, p_3, \dots, p_m$ toplamları 1 olan olasılık dağılımları olsun. Bu durumda, entropi, $H(p_1, p_2, p_3, \dots, p_m)$ şeklinde ifade edilir ve aşağıdaki formüle göre hesaplanır.

$$H = - \sum_{i=1}^m p_i \log_2(p_i) \quad (2.6)$$

Örnekler aynı sınıfa ait ise, $H = 0$, örnekler sınıflar arasında eşit dağılmışsa, $H = 1$, örnekler sınıflar arasında rastgele dağılmışsa, $0 < H < 1$ olmaktadır. Bilgi kaynağında içerilen bilginin beklenen değerini nicel hale dönüştüren entropinin, olasılık dağılımlarına göre bit cinsinden ifadesi Şekil 2.10'daki gibidir.



Şekil 2.10: Entropinin olasılık dağılımlarına göre bit cinsinden ifadesi

Eşit sayıda olasılıklı sonuçlardan uzaklaştıkça, yani öngörülebilirlik arttıkça, entropi miktarı da azalacaktır. Bir bilgi kaynağının entropisi azalır, sonucu tahmin etmek için sormamız gereken soru sayısı da azalır. Maksimum bilgiye, ancak herhangi bir "apriori bilgi" mevcut olmadığında, yani maksimum belirsizlik durumunda erişilir. Entropi, verilerin dağılımları hakkında gerçekçi değerlendirmeler yapabilmemizi sağlayan bir metriktir. Ortak bilgi kavramı, iki küme arasındaki göreceli entropinin bir ölçüsü olmakla birlikte, bilgi fazlalığının ölçüsü olarak da tanımlanır [37].

2.4.Öznitelik Çıkartma Metotlarının İncelenmesi

Orijinal EEG sinyali, zaman domeninde ifade edilir ve sinyalin enerji dağılımı dağınıktır. EEG sinyallerine ait özniteliklerin çıkartılmasına ait zaman, frekans, zaman-frekans ve zaman-frekans-spasyal analiz metotları vardır. Yüksek durağan olmama ve düşük SNR'ye sahip EEG verilerinden kıymetli bilginin elde edebilmesi için, yüksek verimlilikte bir ön-işleme ve öznitelik çıkartma basamaklarından geçirilmesi gereklidir.

Mükemmel bir sınıflandırma sonucu elde edilebilmesi için, efektif bir öznitelik çıkartma metodu uygulanmalıdır. Kullanılacak öznitelik çıkarımı metodu, sınıflandırma işleminin karmaşıklığını ve hesaplanabilirlik maliyetini belirlemektedir. BCI sistemlerinin uygulama ve tasarımı için; Bant Gücü (BP), Güç Spektral Yoğunluğu (PSD), Otoregresif (AR) ve Adaptif Otoregresif (AAR), EEG sinyallerinin büyüklüğü, zaman-frekans domenine ait öznitelikler, Serebro Spinal Sıvı (CSF) ve fraktal boyutlar vb. birçok farklı öznitelik kümeleri vardır [1].

Bu özniteliklerin çeşitli kombinasyonlarının uygulanması ile yapılan deneylerde, özniteliklerin tek tek bağımsız halde kullanılması sonucu elde edilen sınıflandırma performanslarından daha iyi sonuçlar verdiği görülmüştür. Adaptif bant geçiren filtrelerin ve AAR'nin hibrit bir şekilde kullanılması sonucunda sol ve sağ motor imgelemine ilişkin sınıflandırma performanslarının yüksek başarımlı olduğu gösterilmiştir. Adaptif Radyal Tabanlı Fonksiyon (ARBF) ve AAR kombinasyonunun, özellikle Temel Bileşen Analizi (PCA) ve Doğrusal Ayırtaç Analizi (LDA) kullanılarak yapılan sınıflandırmalarda yüksek performans gösterdiği kanıtlanmıştır [49].

EEG sinyalleri durağan olmayan karakteristiğe sahip olduklarından dolayı, zaman skalasında frekans analizi yapılmasına dönük metotların etkin özniteliklerin çıkartılması açısından daha güçlü olduğu söylenebilir. Dalgacık Dönüşümü (WT), bu türden sinyallerin analiz edilmesi açısından oldukça uygundur. PCA ve ICA da, verilerin boyutlarının düşürülmesinde kullanılan öznitelik çıkartma metotları arasındadır.

EEG sinyallerine ait özniteliklerden sinyal tabanlı olanlar arasında, Dalgacık Paketi Dekompozisyonu (WPD) metodu farklı frekans seviyelerindeki dalgacık katsayılarını etmek için gerçekleştirilir ve PCA kullanılarak, bu katsayılarla ait özdeğerler belirlenir. Kabul edilebilir sınıflandırma doğruluğu değerine, mümkün olduğunca az sayıda öznitelikle, en düşük hesaplama yükü altında, en hızlı ulaşacak öznitelik çıkartma metodunun uygulanması tercih edilir [43].

2.4.1. Güç spektrum yoğunluğu tahmin metotları

Frekans domenindeki sinyal gücünün dağılımının hesaplanması ile elde edilen sonuçlar baz alınarak öznitelik çıkartma işlemi gerçekleştirilir. PSD tahminlerinde, parametrik ve parametrik olmayan yaklaşımlar vardır.

2.4.1.1.AAR parametreler ve AR modelleme

Sinyalin parametrik modelinin oluşturulmasına dayalı olan yaklaşımdır. Bir sinyalin PSD'sinin parametrik yaklaşım ile doğru bir şekilde tahmin edilebilmesi için model parametrelerini kullanır. Ham EEG datası üzerinden AAR parametreleri kestirilerek, yüksek boyutlu öznitelik vektör kümesi elde edilebilir. Tek boyutlu $x[n]$ sinyali için M .dereceden AR modeli aşağıdaki gibi yazılır:

$$x[n] = \sum_{m=1}^M c_m x[n-m] + e[n] \quad (2.7)$$

c_m : AR katsayıları

$e[n]$: sonlu varyansa sahip sıfır ortalama hatası

$e[n]$, x sinyalinin önceki değerlerinden bağımsız rastsal işlem olarak kabul edilir.

Buradaki temel problem, AR katsayılarını, x sinyalinin sonlu örneklemeden kestirmektir. Her kanal için, AR katsayıları, Burg algoritması kullanılarak hesaplanabilir. Bu algoritma, katsayıları, ileri ve geri yönlerde sıralı bir şekilde kestirir [26].

Her elektrot kanalı için WT uygulanır. Bant altı kodlaması sonucunda elde edilen öznitelik kümesine ait AR katsayıları çıkartılarak, öznitelik vektör kümesi, belirli bir forma getirilir. Daha sonra, en son öznitelik vektörünü oluşturmak için birleştirilirler. Optimal AR sıralaması, "çapraz-doğrulama" yolu ile bulunabilir [27].

2.4.1.2.Doğrusal modeller

Tahmin metodunun kullanılmasının temel amacı, sinyal üretim sistemini en iyi tanımlayacak model parametreleri kümesini bulmaktır. Bu modeller genellikle gürültü türünden girdilere gereksinim duyarlar. Sinyallerin AR modellenmesinde, tek kanal üzerinden yapılan EEG ölçümünün her örneği, bir önceki örnekleri ile doğrusal olarak ilişkili bir biçimde aşağıdaki formüle göre tanımlanır.

$$y(n) = - \sum_{k=1}^p a_k y(n-k) + x(n) \quad (2.8)$$

$a_k, k = 1, 2, \dots, p$: doğrusal parametreler

n : bire normalize edilmiş ayrık örnekleme zamanı

$x(n)$: gürültü girdisi

Otoregresif Hareketli Ortalama (ARMA) metodu ile çıkartılan doğrusal tahmin edilebilir modelde, her örnek, önceki girdi ve çıktı örnek değerleri tabanında, aşağıdaki formüle göre elde edilir.

$$y(n) = - \sum_{k=1}^p a_k y(n-k) + \sum_{k=0}^q b_k x(n-k) \quad (2.9)$$

$b_k, k = 1, 2, \dots, q$: ek doğrusal parametreler

p ve q parametreleri; modelin derecelerini gösterir.

Çok Değişkenli Otoregresif (MVAR) yaklaşımında ise, çoklu kanallı şema değerlendirmeye alınır. Bu yüzden, her sinyal örneği, hem kendi kanalına ait önceki örnek değerleri, hem de diğer kanallardaki önceki örnek değerleri cinsinden aşağıdaki gibi tanımlanırlar.

$$y_i(n) = - \sum_{k=1}^p a_{ik} y_i(n-k) - \left[\sum_{j=1}^m \sum_{k=1}^p a_{jk} y_j(n-k) \right] + x_i(n) \quad (2.10)$$

m : kanal sayısı

$x_i(n)$: i . kanala olan gürültü girişi

Model parametreleri, iteratif olarak, güncel ve tahmin edilen değerler arasındaki hatayı minimize edecek şekilde hesaplanır [38]. Model katsayılarını etkili bir şekilde bulmak için, bir çok farklı algoritma geliştirilmiştir. Maksimum olabilirlik kestirim metodunda; olabilirlik fonksiyonu, gerçek Gaussian dağılımlı ve yeterince uzun girdi sinyalleri tarafından formüle edilen sistem parametreleri üzerinde maksimize edilir.

Akaike metodunda, hatanın karesinin gradyanı, Newton-Raphson iterasyonu yaklaşımı kullanılarak minimize edilir. Durbin metodunda ise; model katsayılarını, sinyallerin otokorelasyonları ile ilişkilendiren Yule-Walker denklemleri, iteratif olarak çözülür. MVAR katsayıları, Levinson-Wiggins-Robinson algoritması kullanılarak hesaplanır [40].

2.4.1.3. Doğrusal olmayan modelleme

Bu yöntemde, çıkış örnekleri, bir önceki örneklerle doğrusal olmayan bir ilişkiye sahiptir. Genelleştirilmiş Otoregresif Koşullu Heteroskedastite (GARCH) yönteminde her örneğin, bir önceki örnek ile doğrusal olmayan bir fonksiyon aracılığı ile ilişkisi vardır.

Doğrusal olmayan sisteme olan girişin $u(n)$ olduğu ve $x(n)$ şeklinde bir çıkış sinyali üretildiği göz önünde bulundurulursa, böyle bir işlemin analizi için aşağıdaki doğrusal olmayan model kurulur.

$$x(n) = g(u(n-1), u(n-2), \dots) + u_n h(u(n-1), u(n-2), \dots) \quad (2.11)$$

Çarpımsal bağımlılığın anlamı, varyanstaki doğrusal olmayan durum ile ilişkili iken, toplamsal bağımlılığın anlamı da, ortalamadaki doğrusal olmayan durum ile ilişkilidir. Koşullu istatistiksel ortalama ve varyans aşağıdaki gibi tanımlanır.

$$E[x(n) | \mathfrak{N}_{n-1}] = g(u(n-1), u(n-2), \dots) \quad (2.12)$$

$$\text{Var}[x(n) | \mathfrak{N}_{n-1}] = h^2(u(n-1), u(n-2), \dots) \quad (2.13)$$

\mathfrak{N}_{n-1} , geçmiş bilgileri $(n-1)$ zamanından itibaren içermektedir.

Özgün GARCH modelinde, p ve q tahmin derecesidir. Eğer $e(n)$ 'in hata sinyalinin temsil ettiği düşünülürse;

$$\text{Var}[e(n) | \mathfrak{N}_{n-1}] = \sigma^2(n) = \alpha_0 + \sum_{j=1}^q \alpha_j e^2(n-j) + \sum_{j=1}^p \beta_j \sigma^2(n-1) \quad (2.14)$$

α_j, β_j : doğrusal olmayan model katsayıları

İkinci terim (ilk toplam), q . dereceden hareketli ortalama dinamik gürültü terimine ilişkin iken, üçüncü terim (ikinci toplam) de, p dereceli AR modeli temsil eder.

n . zaman örneğindeki hatanın varyansı, hem önceki örnek değerlere hem de önceki varyanslara bağlıdır.

2.4.1.4. Parametrik olmayan yaklaşımlar

PSD hesaplaması, doğrudan sinyal üzerinden yapılır. Periodogram, Welch ve Thomson dönüşümü vb. farklı metotlar vardır. Periodogram, PSD tahmini ayırım zaman dizileri $\{x_1, \dots, x_N\}$ ile tanımlanmış olan veriye Fourier dönüşümü uygulanarak elde edilen sonucu karesinin alınması ile hesaplanır [69].

$$D_N(e^{j\omega}) = \frac{1}{N} \left| \sum_{k=0}^{N-1} x[k] e^{-jk\omega} \right|^2 \quad (2.15)$$

N değeri sonsuza doğru giderken, PSD tahmini gerçek değerine yaklaşır. Sınırlı sayıdaki örnek nedeniyle, yanlış spektrumun bulunması "bias" olarak adlandırılır.

PSD'nin doğruluk kriterlerinden birisi de varyans'tır.

Örnek sayısı sonsuza giderken, varyans sıfıra gidiyorsa güç tahmininin kararlı olduğu söylenebilir. Sonlu sayıda örneğe dayalı tahminlerde varyans sıfır değildir. Varyans ve bias'ın azaltılması için; Welch, Thomson vb. değişik metotlar geliştirilmiştir.

2.4.2.Zaman-frekans domenine ilişkin öznitelik çıkartma metotlarının incelenmesi

Bir sinyalin istatistiksel özellikleri, zamana bağlı olarak değişmiyorsa ya da az değişiyorsa durağan olarak kabul edilir. Eğer sinyaller, istatistiksel olarak durağan ise, hem zaman hem de frekans domenlerinde apaçık bir şekilde karakterize edilirler.

Bunun için FFT, Ayrık Fourier Dönüşümü (DFT), Ayrık Cosine Dönüşümü (DCT), ya da başka yarı optimal dönüşümler uygulanabilir. Bu türden bir analizin, etkili sonuç verebilmesi için, frekans domeninde kesin olarak ayrıştırılabilen türden zihinsel görevlerin seçilmesi gerekmektedir. EEG sinyalleri, durağan olmayan geçişli bir doğaya sahip olduğundan ötürü, farklı zaman dilimlerinde farklı istatistiksel özellikleri olmakla birlikte, spektrumları da zamanla değişir.

EEG sinyali kısa zaman aralıklarında durağan olarak değerlendirilir ve bu özelliğe de; "sözde-durağanlık" adı verilmektedir. Bu yüzden, sinyalin zaman domeninde kısa pencerele bölünüp, her bir bölgedeki frekans değişimlerinin ayrı ayrı incelenmesi gerekmektedir. Fourier dönüşümleri kullanarak, durağan olmayan sinyallerin analizlerini gerçekleştirmek uygun görünmemektedir. Ancak Kısa Zamanlı Fourier Dönüşümü (STFT) kullanılırsa, bu sinyalin zaman-frekans davranışı hakkında bir bilgiye sahip olunabilir. Çoklu kanallı EEG'lerde, elektrotların geometrik pozisyonu spasyal boyutu yansıttığından dolayı, sinyal Uzay-Zaman-Frekans (STF) metotları ile de analiz edilebilir.

2.4.2.1.Kısa zamanlı fourier dönüşümü

Fourier fonksiyonuna, uygun bir pencere eklenerek zaman domeninde çözünürlük elde etmek mümkün hale gelir. STFT denklemi aşağıdaki gibi yazılır.

$$X_{stft}(f, \tau) = \sum_{\tau-N/2}^{\tau+N/2} x(t) \omega^*(t - \tau) e^{\frac{-j2\pi f}{N} t} \quad (2.16)$$

Burada; $x(k)$ orijinal sinyali ifade eder. $\omega^*(t - \tau)$, pencere fonksiyonudur.

$X_{stft}(f, \tau)$; τ merkezli her bir STFT penceresine ait frekans spektrumlarını içermektedir.

STFT'de sinyal, küçük ardıl ya da üst üste binen veri kafeslerine bölünür ve her birisine FFT uygulanır. Ardıl STFT'lerin çıktıları sinyalin zaman-frekans gösterimini sağlar. Sinyal, küçük veri kafeslerine pencere fonksiyonu ile çarpılarak ayrıştırılır.

Tüm sinyalin analiz edilebilmesi için, pencerenin zaman domeninde kaydırılması ve her bir veri kafesi üzerinde FFT işleminin yeniden uygulanması gereklidir. Her bir segment, özel bir pencere fonksiyonu ile çarpılarak, kendi içinde ayrık noktalara bölünür.

Çoklu kanallı EEG durumunda, elektrotların geometrik pozisyonları spasyal boyutu yansıtır ve çoklu yol işleme aracılığı ile gerçekleştirilen STF analizi kullanılır. Böylece zihinsel görevler gerçekleştirilirken, bu görevleri, beyin bölgeleri ile ilişkilendirerek sınıflandırmak mümkün hale gelir [8].

Öznitelikler, sinyal örnekleme aralığında temel öznitelik penceresi aracılığı ile tüm sinyalin taranması sonucunda çıkartılırlar. STFT ve özniteliğe ilişkin pencerelerin genişliğinin ve uzunluğunun, STFT pencere sayısının ve ardıl pencereler arasındaki üst üste binme miktarının seçilmesinin, sistem performansına olan etkisi büyüktür. EEG sinyalleri öznitelik penceresine aktarılırlar ve bu pencere sayesinde EEG sinyalinin frekans bileşenlerinin, FFT metodu ile çıkartılması mümkün hale gelir.

Öznitelik penceresi içindeki temporal çözünürlüğüne, STFT penceresini, veri sekansı boyunca belirli üst üste binmelerle kaydırarak erişmek mümkündür. STFT penceresi boyunca, seçili sinyal segmentinin durağan olduğu kabul edilir. EEG sinyali hızlı değişen spektral içeriklere sahipse frekans çözünürlüğü düşer. Yüksek temporal çözünürlük, STFT penceresini, öznitelik penceresi boyunca geniş üst üste binmeleri kapsayacak şekilde kaydırarak elde edilir. Bu işlem, öznitelik penceresi boyunca gerçekleşen kısa süreli olayların tanımlanabilme potansiyelini maksimize eder [9].

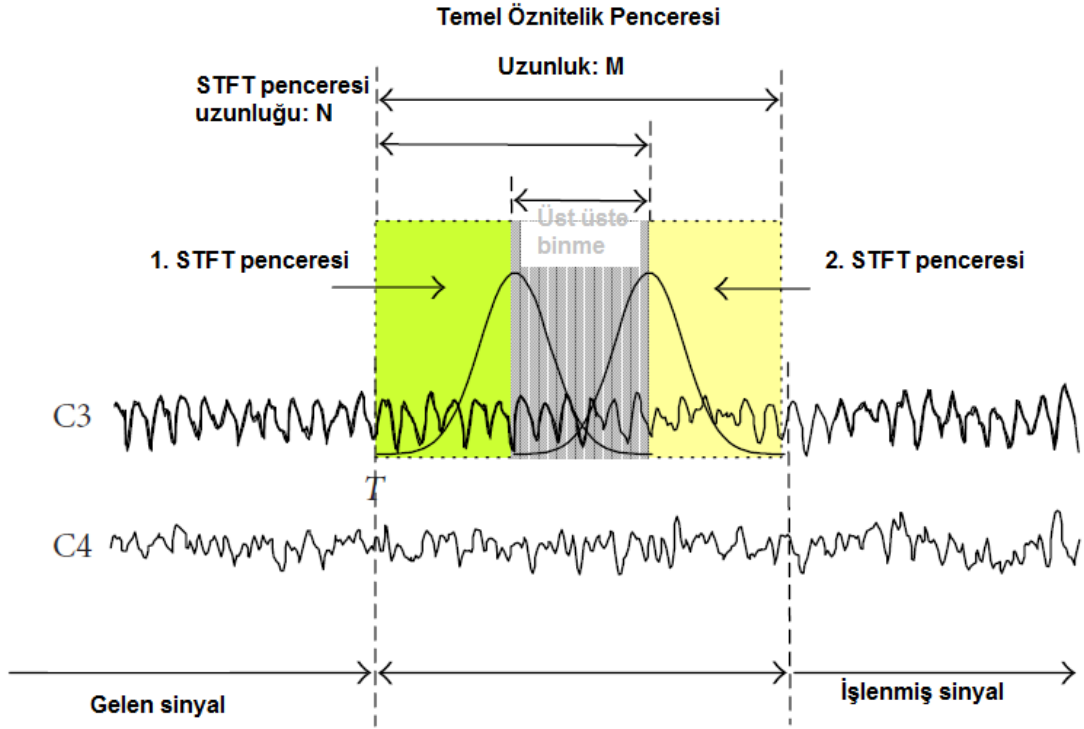
Sinyalin, Fourier dönüşümünü ana öznitelik penceresinde yer alan τ zamanında lokalize etmek için, STFT pencere fonksiyonunun, τ civarında tepe noktasına sahip olması gerekir. Bu karakteristiği sağlayacak çok sayıda pencere fonksiyonu vardır. Örnek olarak, Gaussian penceresi aşağıdaki gibi verilmiştir.

$$\omega(t) = e^{-\frac{1}{2}\left(\frac{t-N/2}{N/2}\right)^2}; 0 \leq t \leq N \quad (2.17)$$

α :resiprokal standart sapma

α , büyüdükçe daha dar pencere üretilmiş olur. Pencerenin uzunluğu N 'dir. Bu sabit parametreler sonucunda, pencerenin boyu ve zaman domenindeki lokalizasyon derecesi belirlenmiş olur.

Bu parametrelerin, optimal şekilde ayarlanması, efektif özniteliklerin çıkartılması açısından oldukça önemlidir. Fourier dönüşümü; sinyali, tüm zaman domeni boyunca yayılan kompleks sinüzoid bileşenlerine ayırmak demektir. Bu yöntemin temel dezavantajı, frekansların zaman içerisindeki değişimleri hakkında hiçbir bilgi vermemesidir. Fourier dönüşümünün, yüksek seviyede durağan olmayan karakteristiğe sahip EEG sinyallerinin analizinde kullanılmaması yeğlenir. Öznitelik penceresi ve STFT penceresini içeren sinyal üzerinde gerçekleştirilen STFT metodu Şekil 2.11'de gösterilmiştir [10].



Şekil 2.11: Öznitelik ve STFT pencerelerinin öznitelik çıkartma işlemi içerisinde gösterimi

2.4.2.2.Sürekli dalgacık dönüşümü

Dalgacık analizinde zaman domeni üzerinde hareket eden farklı türlerde inceleme fonksiyonları kullanılır.Sürekli Dalgacık Dönüşümü (CWT), aşağıdaki denklemde tanımlanmıştır.

$$\Psi(\mu, t) = \frac{1}{\sqrt{\mu}} \int_{-\infty}^{\infty} x(t)\psi\left(\frac{t-\tau}{\mu}\right) dt \quad (2.18)$$

τ , ana dalgacık fonksiyonunun (ψ) sinyal boyunca dönüşümünü sağlarken, μ operatörü de ana dalgacık fonksiyonuna ait frekans skalasının değişiminden sorumludur.

Ana dalgacık fonksiyonu her zaman salınımlı bir formdadır. Ölçeğe ilişkin operatör (μ), sinyalin farklı frekanslarda analiz edilmesini sağlar. Düşük ölçek değerleri, dalgacık fonksiyonunu sıkıştırır ve sinyaldeki yüksek frekans bileşenlerinin tespit edilmesini sağlarken, yüksek ölçek değerleri de dalgacık fonksiyonunu gererek, düşük frekans bileşenlerinin tespit edilmesini sağlar.

Normalizasyon faktörü ($\frac{1}{\sqrt{\mu}}$), enerjinin tüm μ değerleri için normalize edilmesini sağlar. Orijinal sinyalin yeniden oluşturulmasını garantileyecek düzeyde, minimum sayıda dalgacık katsayısı üretecek bilateral dönüşümlere gereksinim vardır. CWT; sinyali, keyfi seçilmiş bir skala üzerinde analiz etme imkanı verirken, DWT ise, sabit frekanslardaki ortogonal dalgacıklardan faydalanarak elde edilen katsayıların fazlalığını azaltmış olur. CWT, ayrık sinyaller üzerine uygulanınca, dalgacık katsayıları, sinyalin örnekleme frekansına ilişkin zaman aralıklarına bağlı olarak elde edilirler.

CWT, gerçek-zamanlı analizler için hesaplama yükü ve karmaşıklığından dolayı tercih edilmemektedir. Biyomedikal, biyogeribesleme ve BCI uygulamaları açısından uygun bir yöntem değildir. Ancak FFT tabanlı algoritmalar geliştirilerek CWT'nin hesaplama hızı arttırılabilir. CWT'nin yardımı ile, zihinsel görevlerin uygulanması esnasında, EEG ritimleri üzerindeki mümkün spektral değişimler saptanabilir. Ardından, kestirilmiş zaman-frekans indeksleri kıyaslanarak, farklı deney koşulları altındaki beyin cevabında önemli istatistiksel değişimler gösterilmiş olur [15].

2.4.2.3. Morlet dalgacık dönüşümü

Morlet Dalgacık Dönüşümü (MWT), sürekli kompleks dalgacık dönüşümü olup sinyali faz ve amplitüt elemanlarına ayırır. Böyle bir yaklaşım sayesinde; alfa, beta, teta, gama vb. frekans bantlarında, zaman-spektral domenine ait analizler yapılabilir. Kompleks Morlet ana dalgacık fonksiyonuna ait parametreler, özel frekans bant genişliğinde temellendirilir ve zaman-frekans domenindeki dalgacık katsayıları çıkartılarak, zaman-frekans çözünürlüğü arttırılabilir.


Morlet ana dalgacık fonksiyonu $\psi(t)$, Gabor dalgacığı olarak da adlandırılır ve aşağıdaki formda ifade edilir [12].

$$\psi(t) = \frac{1}{\sqrt{\pi f_b}} e^{-\frac{t^2}{f_b}} e^{j2\pi f_c t} \quad (2.19)$$

Morlet ana dalgacığı kompleks sinüzoid, Gaussian eğri zarfı ve normalizasyon faktörü bileşenlerinden meydana gelen kompleks dalgadır [13]. Burada f_b , bant genişliği parametresi iken, f_c de merkez frekansa karşılık gelir. Bu dalgacık, kompleks sinüzoidal doğaya sahip modüle edilmiş Gaussian fonksiyonudur ve tüm enerjisi, spesifik zaman domeninde sınırlıdır.

Bu dönüşüm sonucunda, imajiner ve reel bölümlerden oluşan kompleks katsayı değerleri elde edilir. Hesaplama açısından bakılacak olursa, kompleks zaman domenine ait konvolüsyonlar verim düşüklüğü gösterirler. Bu yüzden, frekans domeni cevaplarının ortaya çıkartılması için, ilave olarak FFT uygulanır [14].

Şekil 2.12'de kompleks Morlet dalgacığın zaman-frekans domenine ait fonksiyonu ve bu dalgacığın, spesifik bir frekans bandındaki FFT cevabı gösterilmektedir.



Şekil 2.12: Kompleks morlet dalgacık fonksiyonun zaman-frekans domeninde gösterimi ve FFT cevabı

2.4.2.4. Ayrık dalgacık dönüşümü

Ayrık Dalgacık Dönüşümü (DWT), dalgacık fonksiyonunun girdi sinyali üzerinde ayrık zaman dilimleri içerisinde kaymasını ve skalalandırılmasını (genişleme ya da daralma) sağlar.

Literatürde, aşağıdaki değişkenler kullanılmıştır.

g : yüksek geçiren dalgacık filtresi

h : alçak geçiren ölçeklendirme filtresi

J : toplam oktav sayısı

j : mevcut oktav ($1 \leq j \leq J$)

N : toplam girdi sayısı

n : mevcut girdi ($1 \leq n \leq N$)

L : filtre genişliği

k : mevcut dalgacık katsayısı

$W_f(a, b)$: CWT'ye ait fonksiyon

$W_h[j, n]$: DWT'ye ait fonksiyon

$W[j, n]$: DWT fonksiyonuna ait ayrık skala fonksiyonu

$W[0, n]$: girdi sinyali

Sınıflandırma işleminde kullanılacak her deneme için hesaplanan öznitelik vektörleri, DWT'nin katsayılarıdır. Bu katsayılar, sinyalin farklı frekans bantlarına karşılık gelmektedir. Genel olarak DWT yöntemi ile çıkartılan öznitelikler; enerji, entropi veya standart sapmaya ilişkin olabilir. Öznitelik çıkartılması probleminde, bilinear model tabanlı birinci ve ikinci dereceden spasyal ve temporal öznitelikler dikkate alınır.

DWT katsayılarının mutlak değerlerinin ortalamaları, standart sapmaları, komşu alt frekans bantlarının mutlak değerlerinin ortalamalarının oranları da, istatistiksel tabanlı öznitelikler olarak kullanılmaktadır [17].

Ölçeklendirme fonksiyonu; filtre katsayılarının yinelemeli bir şekilde uygulanması ile elde edilir. Ölçeklendirme ve dalgacık fonksiyonu hakkındaki tüm bilgiler, onlara ait katsayılar tarafından belirlenir.


Ölçeklendirme fonksiyonu aşağıdaki gibidir;

$$\phi(t) = \sqrt{2} \sum_k h[k]\phi(2t - k) \quad (2.20)$$

Dalgacık fonksiyonu da aşağıdaki gibi verilmiştir;

$$\psi(t) = \sqrt{2} \sum_k g[k]\phi(2t - k) \quad (2.21)$$

Burada $h[k]$ ve $g[k]$, sırasıyla alçak geçiren ve yüksek geçiren filtrelere ait sınırlı katsayılar kümesidir. Bu şablon, Dalgacık Filtre Bankası (WFB) formatında Şekil 2.13'te gösterilmiştir.



Şekil 2.13: WFB a) yeniden oluşturma b) dekompozisyon

Alçak geçiren filtrenin çıkışı (yaklaşıklık sinyali) aşağıdaki gibi ifade edilir:

$$W[j, n] = \sum_{m=0}^{N-1} W[j-1, m]h[2n - m] \quad (2.22)$$

Yüksek geçiren filtrenin çıkışı (detay sinyali) da aşağıdaki gibi ifade edilir:

$$W_h[j, n] = \sum_{m=0}^{N-1} W[j-1, m]g[2n - m] \quad (2.23)$$

Ölçeklendirme ve kaydırma faktörlerinin a ve b olduğu, tekil bir örnekleme zamanı varsayımı altında, genel bir dalgacık fonksiyonu (ψ)'ye sahip DWT, sinyalin ayrıklaştırılmış örnekleme sekansına $x[n]$ bağlı olarak aşağıdaki gibi ifade edilir [18].

$$W_f[a, b] = \frac{1}{\sqrt{a}} \sum_{n=b}^{aL+b-1} x[n] \psi\left(\frac{n-b}{a}\right) \quad (2.24)$$

W_f , analiz edilen sinyal ile, seçilmiş spesifik dalgacık fonksiyonu arasındaki benzerliği gösteren dalgacık katsayılarını içerir. DWT, ikili skalada hiyerarşik olarak sinyali düşük frekans bileşenlerine W_{f,A_i} (yakınlık katsayıları) ve yüksek frekans bileşenlerine W_{f,D_i} (detay katsayıları) ayrıştırır. Bu şekilde, verilerin alt örnekleme yapılmış olur. Ayrıştırma seviyesi, sinyalin örnekleme frekansı (f_s) ile ilişkilidir.

\mathcal{L} -seviyeli ikili ayrıştırmada yakınlık katsayıları W_{f,A_i} , $\left[0, \frac{f_s}{2^{\mathcal{L}}}\right]$ Hz.'lik frekans aralığında bilgi içerirken, detay katsayıları W_{f,D_i} , $\left[\frac{f_s}{2^{\mathcal{L}}}, \frac{f_s}{2^{\mathcal{L}-1}}\right]$ Hz.'lik bilgi içerirler [17].

2.5.Öznitelik İndirgeme Metotlarının İncelenmesi

Bir sınıflandırma ya da bağlanım modelinin karmaşıklığı, girdi sayısı ile ilintilidir. Bu değer, modelin eğitilmesine ait zamanı, uzay karmaşıklığını ve gereken öğrenme örneği sayısını bize verir. Bazı özniteliklerin, fazlalık ve/veya mevcut veriyi ayırt etmekte yetersiz olduğu durumlar bulunmaktadır. Bu yüzden, öznitelik indirgeme işlemi sınıflandırıcının daha sağlam bir çözümü öğrenmesi ve daha iyi bir performans sergilemesinde hayati önem arz etmektedir. Veri boyutunun indirgenmesi ve öznitelik çıkartma işlem kapasitesinin hafifletilmesi için; PCA, ICA, LDA gibi metotlar kullanılır. Veri boyutunun indirgenmesi ile, özniteliklerin alt kümesi kullanılır.

2.5.1.Bağımsız bileşenler analizi

ICA, verilen sinyalin kaynaklara ayrıştırılmasında, yani, sinyalin segregasyonu için kullanılır. Örneğin, sol ve sağ elin hareketinin düşünülmesi ile yapılan deneyler, farklı uyarılara karşı, motor korteks ile bağlantılı farklı elektrot bölgelerinin aktivasyonu ile sonuçlanır.

Bir sinyali oluşturan “ n ” sayıda farklı doğrusal karışımın olduğu (x_1, x_2, \dots, x_n) varsayılırsa;

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n; \quad j = 1, 2, \dots, n \quad (2.25)$$

x_j 'yi içeren her karışımın, s_i adet rastsal değişkene sahip, bağımsız bileşenden oluştuğu kabul edilir. Ayrıca, hem karışım değişkenlerinin, hem de bağımsız bileşenlerin sıfır ortalamaya sahip olduğu kabul edilmiştir [6].

A tasarım matrisi, a_{ij} elemanlarından meydana gelsin ve $s_i, (s_1, \dots, s_n)$ bileşenlerinden oluşan rastgele vektör olsun. Bu kabuller altında model aşağıdaki gibi kurulur.

$$x = As \quad \text{ya da} \quad x = \sum_{i=1}^n a_i s_i \quad (2.26)$$

Burada temel problem, A matrisinin elemanlarının ve bağımsız bileşen elemanları olan s_i 'lerin belirlenmesidir. Elemanlar, Gaussian olmayan dağılıma sahip olmalıdır. Kovaryans matrisinin özdeğer ayrıştırılması yolu ile saflaştırma işlemi yapılabilir.

$$VDV^T = E[\hat{x}\hat{x}^T] \quad (2.27)$$

V : ortogonal özvektör matrisi

D : özdeğerlere ilişkin diagonal matris

$\hat{x} = x - E(x)$ şeklinde tanımlanmıştır. Saflaştırma işlemi, \hat{x} 'nin bir dönüşüm matrisi ile çarpılması yoluyla gerçekleştirilir.


$$\tilde{x} = P\hat{x} \quad (2.28)$$

Burada, P matrisi aşağıdaki gibi tanımlanmıştır.

$$P = V\sqrt{D}V^T \quad (2.29)$$

ICA'nın önemli uygulamalarından bir tanesi de, Kör Kaynak Ayrıştırması (BSS)'dir.

BSS; kayıt edilen kanallarda gözlemlenen karışık bilginin kullanılarak, bağımsız kaynak sinyallerini açığa çıkartma ve kestirme yaklaşımıdır. EEG sinyallerinin, BSS konsepti ile ayrıştırılması işlemi Şekil 2.14'te gösterilmiştir[2].



Şekil 2.14: EEG sinyallerinin BSS konsepti ile ayrıştırılması

Orijinal kaynakların bağımsız olması durumunda, $p(s(n)) = \prod_{i=1}^m p_i(s_n)$ kullanışlıdır. Sinyalin mükemmel bir şekilde ayrışması için, karıştırma işleminin yapısı işleme katılmalıdır. BSS modeli, dar bant genişliği ve örnekleme frekansının düşük olduğu durumlarda aşağıdaki gibi kurulabilir.

$$x(n) = Hs(n) + v(n) \quad (2.30)$$

Burada $m \times 1$; $s(n)$, $n_e \times 1$; $x(n)$, ve $n_e \times 1$; $v(n)$ sinyalin kaynak vektörlerini, gözlenmiş sinyalleri, ayrık zaman n 'ye ait gürültüyü göstermektedir. H karışım matrisidir ve boyutu $m \times n_e$ 'dir. W matrisi, $x(n)$ hakkındaki bilgiyi kullanarak, orijinal sinyal kaynaklarını bağımsız bileşenler şeklinde yeniden kurar. n_e , elektrot sayısını göstermektedir.

$$y(n) = Wx(n) \quad (2.31)$$

2.5.2. Temel bileşenler analizi

PCA, orijinal veri setinin, gürültülü ya da ihtiyaç dışı bölümleri olduğunda, birbiri ile ilintili bilginin çıkartılması için kullanılır. PCA yöntemi ile, öznitelik indirgenmesi ya da öznitelik çıkartılması işlemleri yapılır.

Eldeki veriler yeni bir kartezyen referans sistemine yansıtılarak, yeni bir referans sistemi elde edilir. Bu sayede, temel bileşenler, verinin yansımasının en yüksek düzeydeki değişkenliği şeklinde karakterize edilir. Daha belirgin bir şekilde ifade etmek gerekirse, sıfır ortalama ve birim varyans şeklinde standartlaştırılmış verilere ait kovaryans matrisi hesaplanır ve özvektörleri azalan özdeğer sıralamasına bağlı olarak dizilirler. En yüksek özdeğer olan k ve ona ilişkin özvektörler seçilerek, işlem tamamlanır. İzdüşüm yöntemlerinde verilen d boyutlu uzaydaki girdilerden, $k < d$ boyutlu yeni bir uzayda, minimum bilgi kaybı olacak şekilde bir eşleşim bulunması hedeflenmektedir. x vektörünün, ω yönünde olan izdüşümü, iç çarpım ile elde edilir.

$$z = \omega^T x \quad (2.32)$$

Varyansın maksimum noktaya eriştiği, yani veri noktaları arasındaki farkın, en belirgin olduğu vektör, ω_1 temel bileşenidir. Verinin tek boyutlu izdüşümünün varyansı aşağıdaki gibi bulunur.

$$\text{Var}(z_1) = \omega_1^T \text{cov}(x) \omega_1 \quad (2.33)$$

$\text{Var}(z_1)$ değerini maksimize edecek ω_1 vektörü aranmalıdır. Bu problem, bir Lagrange çarpımını ifade eden forma dönüştürülebilir.

$$\max_{\omega_1} \omega_1^T \text{cov}(x) \omega_1 - \alpha (\omega_1^T \omega_1 - 1) \quad (2.34)$$

ω_1 vektörüne göre, türev alınıp sıfıra eşitlenirse;

$$2\text{cov}(x) \omega_1 - 2\alpha \omega_1 = 0 \quad (2.35)$$

ve buradan $\text{cov}(x) \omega_1 = \alpha \omega_1$ elde edilir.

ω_1 , $\text{cov}(x)$ dizeyinin özvektörü olursa, bu eşitlik sağlanır ve bu durumda α , karşılık gelen özdeğerdir.

$\omega_1^T \text{cov}(x) \omega_1 = \alpha \omega_1^T \omega_1 = \alpha$ değerini en büyük yapmak için en büyük özdeğerli özvektör seçilir. Sonuç olarak, temel bileşen, verilen örneklemin, eşdeğişinti düzeyinin maksimum özdeğerli özvektörüdür [41].

İkinci temel bileşen ω_2 vektörü de, birim uzunlukta ve ω_1 vektörüne dik olmalı ve varyansı olabildiğince büyütmelidir.

Dik olma koşulu, izdüşüm sonrası $z_2 = \omega_2^T x$ değeriyle z_1 değerinin ilintisiz olması için lazımdır. İkinci temel bileşen için kriter aşağıdaki gibi yazılır.

$$\max_{\omega_2} \omega_2^T \text{cov}(x) \omega_2 - \alpha (\omega_2^T \omega_2 - 1) - \beta (\omega_2^T \omega_1 - 0) \quad (2.36)$$

ω_2 vektörüne göre türev alınıp sifıra eşitlenirse;

$$2\text{cov}(x) \omega_2 - 2\alpha \omega_2 - \beta \omega_1 = 0 \quad (2.37)$$

Sol taraftan ω_1^T ile çarpılırsa;

$$2\omega_1^T \text{cov}(x) \omega_2 - 2\alpha \omega_1^T \omega_2 - \beta \omega_1^T \omega_1 = 0 \quad (2.38)$$

$\omega_1^T \omega_2 = 0$ koşulu sağlanmalıdır.

$\omega_1^T \text{cov}(x) \omega_2$ tek boyutlu olduğu için transpozuna eşittir ve $\omega_1, \text{cov}(x)$ düzeyinin özvektörü olduğu için ($\text{cov}(x) \omega_1 = \lambda_1 \omega_1$)

$$\omega_1^T \text{cov}(x) \omega_2 = \omega_2^T \text{cov}(x) \omega_1 = \lambda_1 \omega_2^T \omega_1 = 0 \quad (2.39)$$

olacaktır. Bu yüzden $\beta = 0$ olur ve denklembasitleşerek, aşağıdaki hale gelir.

$$\text{cov}(x) \omega_2 = \alpha \omega_2 \quad (2.40)$$

Buradan, ω_2 vektörünün $\text{cov}(x)$ düzeyinin ikinci en büyük özdeğerli özvektörü olduğu sonucu çıkar. Benzer olarak, diğer bileşenler de, sırayla azalan özdeğerli özvektörler olduğu ispatlanabilir.

2.5.2.1. Kernel PCA

Kernel PCA, verili bir veri seti için $\{x_1, \dots, x_n: x_j \in \mathbb{R}^d, \forall j\}$, veri özellikleri arasındaki doğrusal olmayan ilişkilerin, orijinal gözlemlerin $x_1, \dots, x_n \in \mathbb{R}^d$, her $i = 1, \dots, n$ için x_i 'yi öznitelik uzayına karşılık düşüren fonksiyondaki $\phi(\cdot)$, sütun vektörleri $\phi(x_1), \dots, \phi(x_n)$ tarafından gerilen öznitelik uzayına haritalandırılması yoluyla elde edilmesini amaçlar.

Bu harita $\phi(\cdot)$, genellikle Gaussian fonksiyonu ya da bir polinomyal fonksiyon tarafından belirlenir. Dönüştürülen verilerin $\phi(x_1) \dots \phi(x_n)$, öznitelik uzayında merkezlendiği ve bağımsız rastsal vektörler olarak görüldüğü varsayıldığında, $x_i \in \mathbb{R}^d$ için, rastsal vektörlerin kovaryans matrisi aşağıdaki gibi yazılabilir [42].

$$C = \frac{1}{n} \sum_{j=1}^n \phi(x_j) (\phi(x_j))^T \quad (2.41)$$

Özdeğerler ve özvektörler, kernel matrisi K 'nin dekompozisyonu aracılığı ile hesaplanır.

$$K(x_i, x_j) = \phi(x_i) (\phi(x_j))^T, 1 \leq i, j \leq n \quad (2.42)$$

Temel bileşen çıkartımının amacı; dönüştürülmüş gözlemleri $\phi(x)$, normalize edilmiş özvektörler tarafından gerilen doğrusal uzaya yansıtmaaktır. Yansıtılmış vektöre ait katsayılar aşağıdaki gibi verilmiştir.

$$(\phi(x), c^{-l}) = \sum_{l=1}^n c_l^{-1} K(x_l, x) \quad (2.43)$$

Burada $c^{-l} = (c_1^{-l}, \dots, c_n^{-l})$ ve $l = p, \dots, n$

2.5.3. Yaygın spasyal şablon metodu

EEG sinyalleri, çok düşük spasyal çözünürlüğe sahip olduğundan, EEG tabanlı BCI, verimli spasyal filtrelemeyi gerektirir. Bu yaklaşım, beynin birbiri ile ilişkili bölgelerinden bilgi çıkartmak amacıyla uygulanmaktadır.

EEG verisi, düşük boyutlu öznitelik uzayına Yaygın Spasyal Şablon (CSP) metodu ile izdüşürülür. CSP, ham EEG datasını ön işleme tabi tutarak, doğrusal alt uzay bileşenlerinin tespit edilmesine dayalı bir yöntemdir. Alt uzay sınıflarından bir tanesinin varyansı maksimize edilirken, diğer sınıfın varyansı minimize edilir.

Buna ek olarak, EEG sinyallerinin iki farklı sınıfına ait olan kovaryans matrislerinden eklem diyagonalizasyonu aracılığıyla optimal spasyal filtreler elde edilir [5].

Ham EEG verisine (Q, Q') ait olan normalize edilmiş kovaryans matrisleri aşağıdaki formüle göre hesaplanır.

$$C = \frac{QQ'}{\text{trace}(QQ')} \quad (2.44)$$

Burada Q , $N \times T$ 'lik matris ile ifade edilir. " N " kanal sayısını, " T " ise birim zamandaki örnek sayısını ifade eder. " a " ve " b " sınıfına ait kovaryans matrisleritoplanarak, (C_a, C_b) bileşke kovaryans matrisi $(C_c = C_a + C_b)$ elde edilir.

Bu kovaryans matrisine ait özvektör B_c ve özdeğerlerin " λ " fonksiyonu olan saflaştırılmış dönüşüm, aşağıdaki gibi elde edilir.

$$W = \sqrt{\lambda} B_c' \quad (2.45)$$

Burada; $C_c = B_c \lambda B_c'$ eşitliğini sağladığından dolayı;

C_a ve C_b aşağıdaki matris formuna dönüştürülür.

$$S_a = W C_a W' \quad (2.46)$$

$$S_b = W C_b W' \quad (2.47)$$

S_a ve S_b ortak özvektörleri paylaşırlar. S_a ve S_b 'ye ait özvektör kümesi aşağıdaki gibidir;

$$U^* = U_1, \dots, U_m, U_{N-m+1}, \dots, U_N \quad (2.48)$$

" a " ve " b " sınıfları birinci özvektöre izdüşürüldüğünde " a " sınıfı maksimum varyansa sahip olurken, " b " sınıfı da, minimum varyansa sahip olur.

Eğer son özvektöre izdüşürülürlerse, bunun tam tersi bir durum gerçekleşir. Son durumdaki izdüşüm matrisi aşağıdaki gibi tanımlanır:

$$P = U^* W \quad (2.49)$$

EEG datası (Q) , $Z = PQ$ formatına dönüştürüldüğünde, orijinal sinyalin boyutları düşürülmüş olur. Sınıflandırmada kullanılacak özneteliğin çıkartılması için, Z 'nin normalize edilmiş varyansının logaritması alınmalıdır.

$$f_b = \log\left(\frac{\text{var}(Z_p)}{\sum_{p=1}^{2m} \text{var}(Z_p)}\right), p = 1, \dots, 2m \quad (2.50)$$

CSP, ikiden fazla sınıfa ait veri üzerinde uygulanamaz. k -sınıflı problemler için, her sınıf çiftine ait CSP vektörlerinin birbirlerine bağlanması gerekmektedir [5].

2.5.4. Fisher formülü

Frekans domenindeki bilgi, katlanmış sinyal üzerinde FFT algoritması uygulanarak analiz edilir. Bu işlem, öznelik altkümelerinin indirgenmesi ile sonuçlanır ve bu sayede, ayırt edici öznelikler olarak adlandırılan en efektif spektral bileşenler tespit edilirler. Bu ayırt edici öznelikler, her elektrot tarafından toplanmış EEG verilerinden elde edilen zihinsel görevlerle ilişkilidir ve aşağıdaki formülün uygulanması ile hesaplanır.

$$q(j) = \frac{|\mu_\alpha(j) - \mu_\beta(j)|}{\sqrt{\frac{\sigma_\alpha^2(j) + \sigma_\beta^2(j)}{2}}} \quad (2.51)$$

$q(j)$: j. ayırt edici öznelik

$\mu_\alpha(j)$: I. sınıfa ait olan j. öznelik vektörünün ortalama değeri

$\mu_\beta(j)$: II. sınıfa ait olan j. öznelik vektörünün ortalama değeri

$\sigma_\alpha^2(j)$: I. sınıfa ait olan j. öznelik vektörünün standart sapması

$\sigma_\beta^2(j)$: II. sınıfa ait olan j. öznelik vektörünün standart sapması

Bir örnek uygulama üzerinden anlatılırsa; I. sınıf, EEG datasına MWT uygulanarak çıkartılmış kompleks katsayıların alfa bandındaki FFT dönüşümüne karşılık gelirken, II. sınıf ise, beta bandındaki karşılığıdır.

2.5.5. Tekil değer ayrıştırması

Tekil Değer Ayrıştırması (SVD), genellikle en küçük kareler problemini çözmek için kullanılır. $M \times M'$ lik karesel otokorelasyon matrisi R 'nin özdeğer matrisine

$\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_M)$ ayrıştırılması ile ilişkilidir. $M \times M'$ lik ortogonal matrisin özvektörleri V de, R matrisi ile $R = V\Lambda V^H$ şeklinde bir bağıntıya sahiptir.

Burada $(.)^H$, Hermitian (eşlenik transpoz) operatörüdür.

Eğer $A, R = A^H A$ eşitliğini sağlayan $M \times M$ 'lik bir veri matrisi ise, $M \times M$ 'lik ortogonal matrisi U, V ve $\lambda_i^{1/2}$ elemanlarından oluşan diagonal matris Σ cinsinden aşağıdaki gibi ifade edilir.

$$A = U\Sigma V^H \quad (2.52)$$

Burada $\Sigma^2 = A^H A$ 'dır. U 'ya ait sütunlar sol tekil vektörler iken, V^H 'a ait satırlar da, sağ tekil vektörler olarak isimlendirilir.

2.5.6. Doğrusal ayırtaç analizi

LDA'nın amacı, orijinal kestiricilerin bileşenleri olan yeni bir bileşen üretilmesine dayalıdır. Bu işlem, önceden tanımlı grupların farklarının yeni değişkene göre maksimize edilmesi ile gerçekleştirilir. p -boyutlu kestiricileri tek boyuta indirgeyip sıkıştırmak için kullanılan boyut azaltma tekniğidir. Bu işlemin sonucunda, her sınıfa ait ortalama ayırtaç skorlarının, diğer sınıfların ortalama ayırtaç skorlarından mümkün olacak en büyük derecede farklı, normal dağılımlara sahip olması beklenir.

Ayırtaç skorları, aşağıdaki ayırtaç fonksiyonu ile hesaplanır.

$$D = w_1 Z_1 + w_2 Z_2 + \dots + w_p Z_p \quad (2.53)$$

Bu işlem sonucunda elde edilen ayırtaç skoru, tahmin unsurlarının ağırlıklandırılmış doğrusal bileşenlerinin kombinasyonlarıdır. Ağırlıklar, sınıflar-arası ortalama ayırtaç skorlarının farklarını maksimize edecek şekilde kestirilirler. Genellikle sınıfların ortalamaları arasında yüksek benzemeziğe sahip tahmin unsurlarının ağırlıkları yüksek iken, benzerlik oranı yükseldikçe, ağırlıklar da azalır [7].

2.6. Özniteliklerin Seçimine Yönelik Geliştirilen Algoritmaların İncelenmesi

Yüksek boyutlu verilerin yaygınlaşmasıyla birlikte, Öznitelik Seçimi (FS)'ye ait metotların, öğrenme ve modelleme işlemlerindeki uygulama alanları da, artan önemle genişlemiştir. Suni bilgilerin ve birbirleri ile ilişkisi olmayan özniteliklerin çokluğunda, değerli olan özniteliklerin alt kümesinin, orijinal öznitelik kümesinden seçilmesi, sınıflandırma performansının artmasına katkıda bulunmaktadır. Bilgi miktarındaki fazlalığın indirgenmesi ve yüksek sınıflandırma doğruluğu gösterecek özniteliklere

ilişkin kıymetli bilgilerin elde edilmesi bu sayede mümkün olmaktadır. FS işlemi, genellikle aşağıdaki bileşenlerden meydana gelir;

- 1)Belirli bir arama stratejisi tabanında öznitelik alt küme adaylarının üretilmesi
- 2)Belirli hesaplama ölçütüne göre seçilen öznitelik alt kümelerinin hesaplanması
- 3)Hesaplama ölçütüne göre en iyi değeri veren bir önceki alt kümenin performansı ile seçilen öznitelik alt kümesinin performansının kıyaslanması
- 4)Daha iyi bir alt kümenin tespit edilmesi durumunda, elde edilmiş optimal altı çözümün bir önceki en iyi ile yer değiştirmesi
- 5)Bu işlemlerin, öznitelik alt kümelerinin verimsizce araştırılmasını engellemek için belirli bir durdurma kriterine erişilinceye kadar tekrarlanması

Bazı durdurma kriterleri apriorik bir eşik değeri ile belirlenirken, bazı durdurma kriterlerine ait eşik değerleri de, algoritma ile belirlenir.

Ardından, FS işlemi sonucu seçilmiş öznitelik alt kümeleri doğrulama amacıyla; Yapay Sinir Ağları (ANN), Karar Destek Makinaları (SVM) ya da, Sade Bayesian (NB) gibi çeşitli sınıflandırma metotları tarafından test edilirler [54,55].

Son yıllarda, birçok meta-buluşsal FS algoritmaları ve onların geliştirilmiş versiyonları, değişik psikiyatrik bozukluğa ilişkin sınıflandırma problemlerine uygulanmıştır [56-60]. Bu metotların uygulamaları, tasarım işlemleri açısından farklılaşmakta ve üç temel kategoride sınıflandırılmaktadırlar [61].

Eğer bir algoritma, herhangi bir öğrenme algoritmasından bağımsız bir FS işlemi gerçekleştiriyorsa, o zaman filtre yaklaşımı şeklinde değerlendirilir. Filtre yaklaşımı, bir ön işleme adımı kullanarak öznitelikleri seçer ve bu yaklaşımın temel dezavantajı, indüksiyon algoritmasının performansı üzerinden seçilen öznitelik alt kümesinin etkilerini tamamen dışlamasıdır. İkinci olarak, hesaplama prosedürünün bir öğrenme metodu tarafından sürdürülmesine dayanan FS algoritmaları vardır. Burada, öznitelik altkümüesi seçimi, bir indüksiyon algoritması kullanılarak gerçekleştirilir.

Bunun gerçekleştirilebilmesi için, öznitelik altkümüesi seçim algoritmasının kendi hesaplamasının bir parçası olan indüksiyon algoritmasını kullanarak, daha iyi bir öznitelik altkümüesi için araştırma yapması gerekmektedir.

Böylesi bir metot, en iyi öznitelik altkümüesini; indüksiyon algoritması tarafından kestirilen doğruluğu kullanarak, öznitelik altkümüesi uzayı boyunca seçilmiş altküme performansının ölçüsüne göre araştırır. Bu türden bir yaklaşım; sarıcı (wrapper)

yaklaşım olarak nitelendirilir. Filtre metotları, işlemsel açıdan basit ve yüksek boyutlu veri setine kolayca ayarlanan bir yapıda olmakla birlikte, seçilen öznitelik ve sınıflandırıcı arasındaki etkileşimi görmezden gelirler. Halbuki, sarıcı yaklaşımlar, öznitelik vektörleri arasındaki korelasyonları içerirler ve birbirleri ile olan etkileşimlerini göz önünde bulundurlar. Buna karşın, aşırı uyum gösterme riskleri vardır ve yüksek hesaplama yüklü sınıflandırıcıları kurarken, işlemsel açıdan yoğunurlar [62].

Son olarak, gömülü yaklaşımda, FS işlemi ve öğrenme algoritması dönüşümlü olarak çalışırlar. FS işlemi ve sınıflandırıcı arasındaki bağlantı kuvvetlidir. Yine de, sarıcı metotlar, arama uzayını kapsamakta daha beceriklidirler.

Araştırmacılar, mevcut nümerik metotların hesaplama açısından yetersizliklerine rağmen, karmaşık optimizasyon problemlerini çözmek için kullanılan simülasyonlar temelindeki meta-buluşsal algoritmalarından oldukça memnun kalmışlar ve bir çok optimizasyon problemine ayrıntılı bir şekilde uygulamışlardır.

Meta-buluşsal algoritmaların yaygın özellikleri arasında, algoritma prensiplerini, olasılık ve rastsal süreçleri kullanarak, sürü zekası ya da biyolojik evrimsel süreçleri taklit etme kapasitesi gelmektedir. Bu bağlamda; Genetik Algoritma (GA), Diferansiyel Gelişim (DE), Parçacık Sürü Optimizasyonu (PSO), Karınca Koloni Optimizasyonu (ACO), Ateş Böceği Algoritması (FA), ısı işlem algoritması vb. algoritmalar, doğa esinlenmeli FS algoritmaları arasında yer almaktadırlar. Standart uygulamalardaki olumsuzlukların üstesinden gelmek için, bu belirtilen algoritmaların modifiye edilmiş ve geliştirilmiş versiyonları kullanılmaktadır [63,64].

2.6.1.Parçacık sürü optimizasyonu

PSO algoritması, her bir parçacığın problem için muhtemel bir çözümü temsil ettiği parçacıkların popülasyonu ile uğraşır. Parçacıklar çok boyutlu araştırma uzayı boyunca akış içerisinde dirler ve her bir parçacığın pozisyonu kendi ve komşularının tecrübelerine göre ayarlanmaktadır. Parçacığın pozisyonu, mevcut pozisyonuna hız vektörü ilave edilerek, aşağıdaki gibi değiştirilir [65].

$$x_i(t + 1) = x_i(t) + v_i(t + 1) \quad (2.54)$$

Burada;

$x_i(t)$: t . zaman adımında uzaydaki i . parçacığın pozisyonu

$v_i(t + 1)$: $(t + 1)$. zaman adımında i . parçacığın hızı

Hız vektörü, optimizasyon işlemini yönlendirir ve hem parçacığın deneysel bilgisini, hem de sosyal açıdan çevre parçacıklardan elde etmiş olduğu bilgiyi ifade eder.

Bir parçacığın bilişsel bileşeni olarak tanımlanan deneysel bilgisi, parçacığın başlangıçtan bu yana bulmuş olduğu kendisine ait en iyi pozisyonu ile, mevcut pozisyonu arasındaki mesafe ile ilişkilidir.

Sosyal bilgi ise; hız denkleminde ait bir bileşen olarak tanımlanır. İki farklı PSO algoritması "gbest", "pbest", tanımlanmış olup, aday fonksiyonları açısından değişkenlik göstermektedirler. Global optimal PSO (gbest PSO), her bir parçacığın komşuluğu, sürünün bütününe kapsamaktadır. gbest-PSO'nun sahip olduğu sosyal ağ, yıldız topolojisini temsil etmektedir. Yıldız komşuluk topolojisinde, parçacık hız değişiminin sosyal bileşeni, sürüdeki tüm parçacıklara ait bilgiyi temel alır.

Bu durumda, sosyal bilgi, sürü tarafından bulunan en iyi pozisyonudur ve $\hat{y}(t)$ olarak gösterilir. gbest-PSO için i . parçacığın hızı aşağıdaki gibi hesaplanır [28].

$$v_{ij}(t + 1) = v_{ij}(t) + c_1 r_{1j}(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t)[\hat{y}_j(t) - x_{ij}(t)] \quad (2.55)$$

Burada;

$v_{ij}(t)$: t . zaman adımında $j = 1, \dots, n$ boyutunda i . parçacığın hızı

$x_{ij}(t)$: t zaman adımında j boyutunda i . parçacığın pozisyonu

c_1, c_2 : bilişsel ve sosyal bileşenlerin katkısını ölçeklendirmek için kullanılan pozitif ivme sabitleri

$r_{1j}(t), r_{2j}(t)$: algoritmaya stokastik özellik katan $[0,1]$ aralığında tek biçimli dağılımdan üretilmiş rastgele sayılar

$y_i(t)$: i . parçacığa ilişkin en iyi kişisel pozisyon yani parçacık tarafından başlangıçtan itibaren erişilmiş en iyi pozisyon

Minimizasyon problemleri için bir sonraki zaman adımında kişisel en iyi pozisyon aşağıdaki gibi hesaplanır.

$$y_i(t+1) = \begin{cases} y_i(t); & f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1); & f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (2.56)$$

$f: \mathbb{R}_x^n \rightarrow \mathbb{R}$ uygunluk fonksiyonudur. Uygunluk fonksiyonu, karşılık gelen çözümün optimum çözüme ne kadar yakın olduğunu ölçülemektedir. Bir parçacığın çözümünün performansına ait kriterdir.

$\hat{y}(t)$, t . zaman adımında global optimum pozisyon aşağıdaki gibi tanımlanır.

$$\hat{y}(t) \in \{y_0(t), \dots, y_{n_s}(t)\} \mid f(\hat{y}(t)) = \min\{f(y_0(t)), \dots, f(y_{n_s}(t))\} \quad (2.57)$$

" n_s " indisi sürüdeki toplam parçacık sayısını temsil etmektedir.

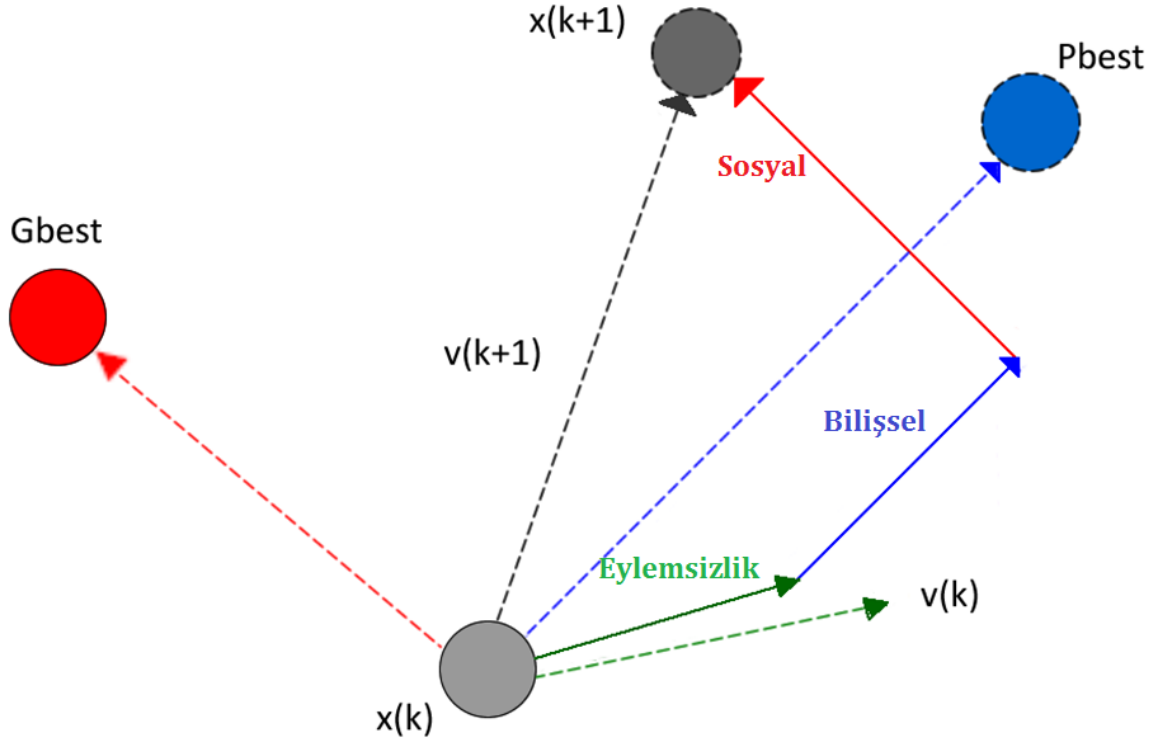
Lokal optimal PSO (pbest-PSO), her bir parçacık için daha küçük komşulukların tanımlandığı, halka sosyal ağ topolojisine sahiptir. Sosyal bileşen, çevrenin bölgesel bilgisini yansıtan parçacığın komşuluğu içindeki bilgi anlamında değişimi gösterir.

Hız denklemindeki parçacık hızına olan sosyal katkı, parçacığın komşuluğunda bulunan en iyi pozisyon ve parçacık arasındaki mesafe ile doğru orantılıdır.

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_{1j}(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t)[\hat{y}_{ij}(t) - x_{ij}(t)] \quad (2.58)$$

Burada $\hat{y}_{ij}(t)$, i . parçacığın komşuluğunda bulunan en iyi pozisyonudur. Bölgesel en iyi pozisyon, aynı zamanda, komşu en iyi pozisyon olarak da ifade edilir. Hız hesabı için kullanılan ifade üç farklı kavramı kuşatmaktadır. Önceki hız $v_i(t)$, önceki uçuş yönünün hafızası olarak çalışır. Bu hafıza, momentum olarak değerlendirilebilir ve parçacığın beklenmedik bir şekilde yön değişimini sınırlandırıp, mevcut yön temelli değişimi garantiler. Bu bileşen; "eylemsizlik bileşeni" olarak da adlandırılır.

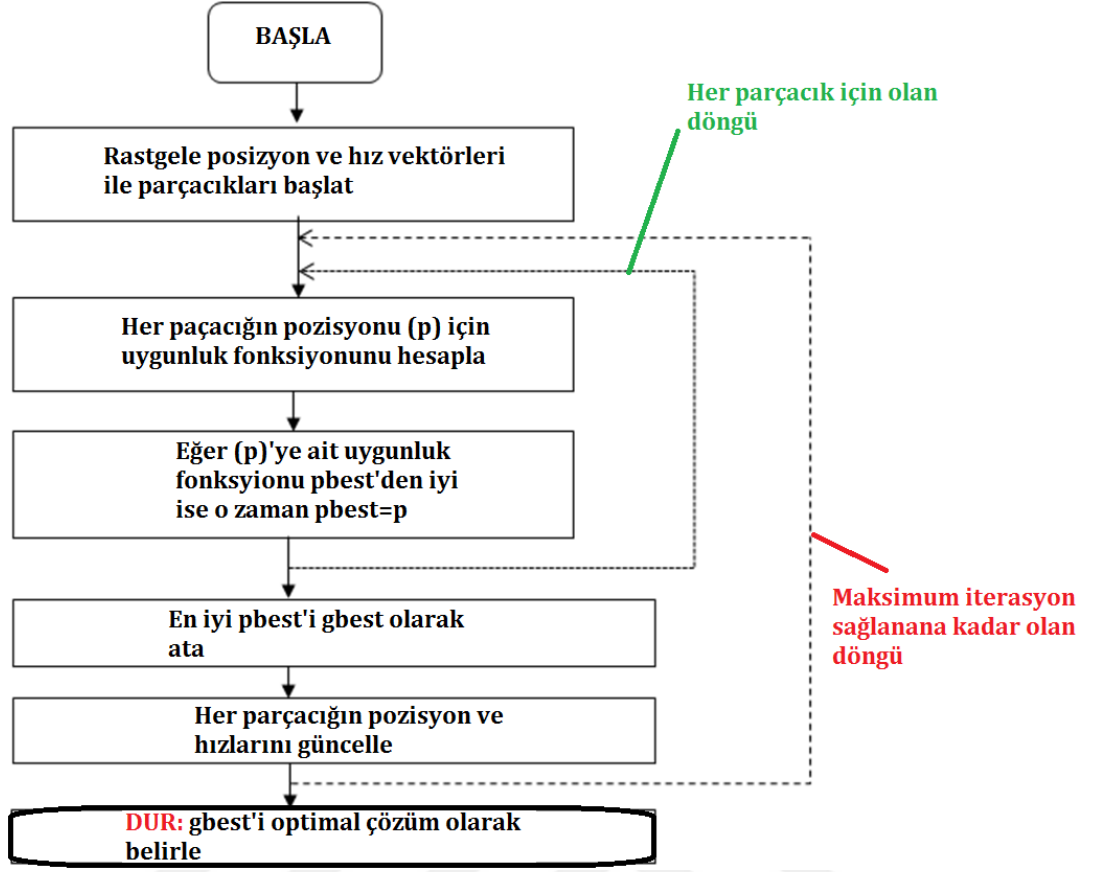
Bilişsel bileşen, $c_1 r_1 (y_i - x_i)$ parçacık için en iyi olan pozisyonun bilgisini gösterir. Bireyler, geçmişte aldıkları en iyi durumlara doğru dönme eğilimini yansıtır. Sosyal bileşen de $c_1 r_1 (\hat{y} - x_i)$, komşular veya parçacıkların bir grubuna göre i . parçacığın performansını tanımlar. Sosyal bileşenin etkisi, her bir parçacığın, parçacığın komşuluğunda bulunan en iyi pozisyona doğru evrilmesi olarak açığa çıkar. Bilişsel ve sosyal bileşenlerin katkısı, stokastik değerlere sahip ağırlıklar cinsinden ölçülmektedir. Hız denkleminin etkisi, iki boyutlu vektör uzayında Şekil 2.15'teki gibi gösterilebilir.



Şekil 2.15: PSO'ya ilişkin vektör uzayının şematik gösterimi

Optimizasyon işlemi, iteratif bir işlemdir. Algoritmaların tekrar eden iterasyonları, bir durdurma kriteri sağlanıncaya kadar gerçekleştirilmektedir. Bir iterasyonda, kişisel en iyi pozisyonlar belirlendikten sonra, global en iyi pozisyon bulunur ve arkasından her bir parçacığın hızı, adaptif bir şekilde ayarlanır.

Her iterasyonda, belirlenmiş sayıda fonksiyon hesaplaması yapılır. Bir fonksiyona ait inceleme, problemi karakterize eden uygunluk fonksiyonunun hesaplanmasına karşılık gelir. Temel PSO için, toplam olarak iterasyon başına n_s (sürüdeki toplam parçacık sayısı) kadar fonksiyon değerlendirmesi icra edilir. PSO algoritmasının akış şeması Şekil 2.16'da gösterilmektedir.



Şekil 2.16: Temel PSO algoritması akış şeması

Algoritmanın ilk adımı, sürüye ve kontrol parametrelerine başlangıç değerleri atamaktır. Bu değerler; ivme sabitleri, başlangıç hızları, parçacık pozisyonları ve kişisel en iyi pozisyonları içermektedir ve aynı zamanda, pbest-PSO için komşu büyüklüğünün de tanımlanması gerekmektedir. Genellikle, parçacık pozisyonları; araştırma uzayı üzerinde, düzgün bir şekilde başlangıç değerlerine atanır. PSO'nun performansı, sürünün başlangıçtaki farklılığına hassas bir şekilde bağlıdır. Araştırma uzayının bölgelerine, başlangıç sürüsü düzenli bir şekilde dağıtılmazsa, PSO optimum çözümü bulmakta zorlanır. Parçacık pozisyonları, başlangıç değerlerine aşağıdaki gibi atanmaktadır.

$$x(0) = x_{\min,j} + r_j(x_{\max,j} - x_{\min,j}), \forall j = 1, \dots, n_s \quad (2.59)$$

x_{\min} , x_{\max} vektörleri, her bir boyuttaki minimum ve maksimum bölgeleri temsil etmektedir. PSO'yu yönlendiren özellik, sosyal etkileşimdir. Sürü içindeki parçacıklar birbirlerinden öğrenirler ve elde edilen bilgiye bağlı olarak, daha iyi komşularına daha çok benzeyecek şekilde hareket ederler. PSO'nun performansı, sosyal ağın yapısına oldukça bağlıdır.


gbest PSO, diğ er ađ yapılarına göre çok daha hızlı yakınsayabilmekte, ancak lokal minimaya takılma ihtimali de artmaktadır. Her parçacık; komşuluğ unda bulunan en iyi çözüme dođ ru hareket etmek suretiyle, ona benzemeye ç alıřır.

2.6.2.Genetik algoritma

GA; yönlendirilmiş rastgele arařtırmaya dayalı evrimsel algoritmalarının bir türüdür. Dođ al seleksiyon ile, canlılarda bulunan genetik gelişimin benzetiş imini yapmaktadır. Algoritma, arařtırma uzayında bulunan çözümlerin bazılarının oluşturduđ u bir başlangıç popülasyonunu kullanmaktadır. Başlangıç popülasyonu, her nesilde, dođ al seleksiyon ve reproduksiyon iş lemleri aracılıđ ı ile, ardıl bir şekilde geliştirilir. En son neslin en uygun bireyi, problem için optimal çözümler olmaktadır. Basit bit dizileri kullanılarak, karmařık yapılar kodlanabilir. Yapılar, çözülecek problem için mümkün çözümleri temsil etmektedir. Bunlar, muhtemel tüm çözümleri iç ine alan arařtırma uzayından alınır ve bu dizilerin belirli bir miktarı, genetik algortimanın kullanacađ ı popülasyonu oluşturur[28].

Daha sonra, temel genetik operatörlerin belirli bir seti, ard arda gelen nesillerde çözümleri geliřtirmek amacı ile kullanılır. Bu iş lem, uygun bir şekilde kontrol edilirse, çözümler popülasyonunun ortalama kalitesi hızlı bir geliş me gösterir.

Genetik operatörlerden olan çaprazlama ve mutasyon, gelecek nesillerdeki çözümleri üretmek amacıyla kullanılmaktadır. Kalite ve uygunluk deđerlendirme iş lemi, reproduksiyon olayında uygulanan seçme iş lemini gerçekleřtirmek için, her bir bireye uygulanır. Birbiri boyunca devam eden nesillerin geliřtirilmesi ve deđerlendirilmesi çevrimi, optimal çözümler bulununcaya kadar sürer. Ş ekil 2.17'de GA'nın akıř diyagramı gösterilmektedir.



Şekil 2.17: GA'nın akış diyagramı [29]

GA'larda karmaşık yapıların ilk ve en çok kullanılan mekanizması, $[0,1]$ ikili sayı kodlamasını kullanan dizidir [30].

Çözümlerin kalitesinin belirlenmesinde kullanılan teknik, GA'nın performansında oldukça etkilidir. GA'lar, normalizasyon işlemine karşı aşırı duyarlıdır. GA'lar bir taraftan iyi çözümlerin bulunduğu tarafa doğru odaklanırken, global optimizasyon için, araştırma uzayında yeterli bir ıraksamanın sağlanması gereklidir. Aksi takdirde, erken yakınsama problemi ortaya çıkar ve tüm uzayın tamamen araştırılmasının önüne geçilmiş olur. Normalizasyon işleminde yaygın olarak kullanılan yöntem; "ölçekleme penceresi" işlemidir. GA'lar; reprodüksiyon, çaprazlama, mutasyon gibi operatörlerin değişik türlerini içerirler. Bu operatörlerin uygun kombinasyonlar içerisinde uygulanmaları, karmaşık problemlerin çözümü açısından oldukça önemlidir.

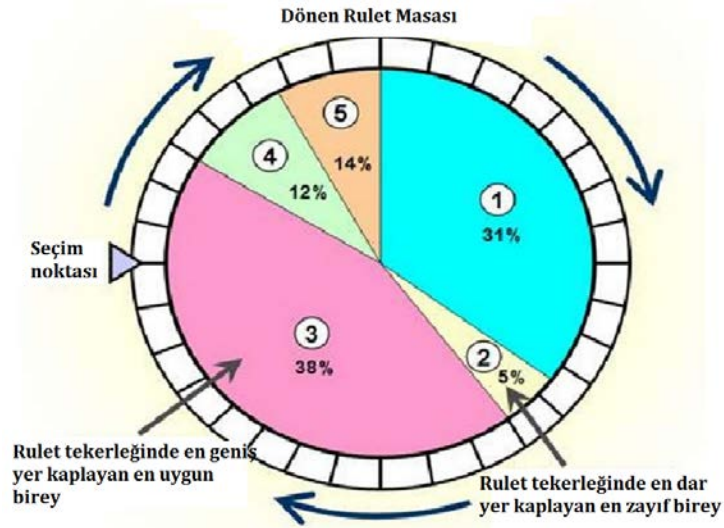
Reprodüksiyon operatörü, doğal seçme işlemine ilişkin bir kavramdır. Kalitesi yüksek bireylerin, hayatta kalmaları ve sayılarının artması, kalitesi düşük bireylerin de, azalarak kaybolması ilkesine göre oluşturulan bir GA operatörüdür. Bireysel yapılar bir kuşaktan diğerine geçerken, kalite değerlerine göre daha fazla üreme şansları vardır.

Bundan dolayı, kaliteli çözümlerin baskın olmaları, kalitesiz olanların da. nesillerinin tükenmeleri sağlanır. Yöntem, genel olarak rulet oyununa benzetilir. Jenerasyondaki bireylerin toplam uygunluk değeri rulet tekerleğinin büyüklüğünü verir ve her bir birey; rulet tekerleğinde uygunluk değeri kadar yer alır. Bunun için, sıfır ile toplam uygunluk değeri arasında rastgele bir sayı üretilir ve bu sayının, tekerleğin hangi parçasına denk geldiğine bakılarak birey seçilir. Böylelikle, çemberin bir defa döndürülmesiyle bir sonraki nesle aktarılacak olan bireylerden bir tanesi seçilmiş olur. Uygunluk değeri en iyi olan adaylar, eşleştirme havuzu olarak adlandırılan bir havuzda toplanarak, diğer genetik operatörlerin uygulanması için hazırlanırlar. Aynı işlem, her döngüde devam ederek, nesil devamlılığı sağlanır [31].

Her bir birey için, seçilme olasılığı veya yaşama olasılığı, P_k aşağıdaki denklem kullanılarak elde edilir.

$$P_k = \frac{\phi_k}{\sum_{j=1}^n f_j}, k = 1, 2, \dots, n \quad (2.60)$$

Burada ϕ_k , her bir bireye ait uygunluk değerleridir. Şekil 2.18'de, her bir bireyin yüzdesine göre oluşturulmuş çember görülmektedir.



Şekil 2.18: Rulet tekerleği seçim yöntemi

Seçim işlemi için, "Rulet Tekerleği" kullanılır. Rulet çevrilir, hangi bireyin üzerinde durur ise, o birey seçilir. Popülasyon içersindeki bireyler, 0 ile 1 değerleri arasında rastgele üretilen bir değere denk gelecek şekilde çevrilme işlemine tabi tutulurlar. Üretilen bu sayı ile, rulet tekerleği üzerindeki bir birey seçilir. Bu yöntemin olumsuz olarak nitelendirilebilecek bir özelliği ise, uygunluk derecesi yüksek bir bireyin seçilmeyip, yok olma ihtimalinin olmasıdır.

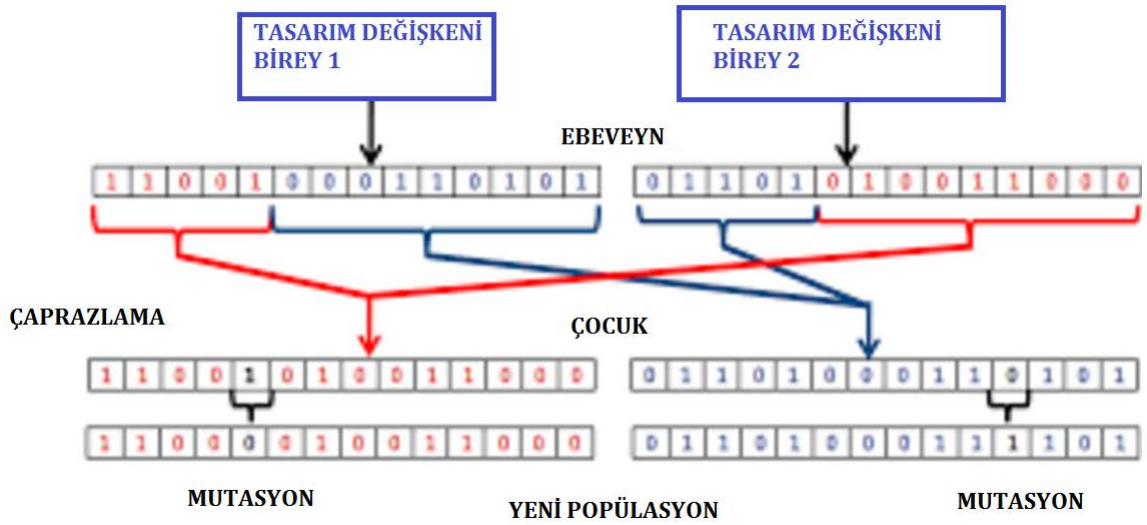
Çaprazlama operatörü ise; seçilen iki ebeveynin genlerinin, rastgele seçilen bir noktadan, bir bütün oluşturacak şekilde değiştirilmesidir. Eşleştirme havuzunda bulunan yapıların birer çifti, rastgele seçilir ve çaprazlama operatörü, bu iki yapıdan yeni iki yapı meydana getirmek için uygulanır. Çaprazlama operatörü, seçilen kodlama türüne göre çeşitlilik göstermektedir. İkili kodlamada, genel olarak çaprazlama noktası bir tanedir. Ancak, çaprazlama noktası birden fazla seçilebilmektedir. Gerçek kodlamanın kullanıldığı GA optimizasyonlarında, genellikle aritmetik çaprazlama kullanılır.

GA'da belirli bir döngü değerine gelindikten sonra, bireyler birbirlerine benzemektedirler. Bu yüzden, araştırma uzayı daralmakta ve yeterli çeşitlilik sağlanamamaktadır. Bu durumda, bireyi oluşturan dizi içinde, bir veya daha fazla gen rastlantısal bir şekilde değiştirilir. Bu işleme;"mutasyon" adı verilir. Mutasyon operatörü de, seçilen kodlama türüne göre çeşitlilik göstermektedir. İkili kodlamanın kullanıldığı GA optimizasyonunda, mutasyon işlemi sırasında bir gen alınarak, değeri "1 ise 0" ve "0 ise 1" olacak şekilde değişikliğe uğratılır.

Mutasyon sayesinde, görülmemiş veya araştırılmamış çözüm elemanlarının bulunması sağlanır. Mutasyon işlemi ile, GA'nın optimal altı çözümlere takılmasının önüne geçilmiş olunur ve daha önceden elenmiş iyi çözüm elemanlarının tekrar üretilmesi sağlanır.

Eğer, GA optimizasyonu için parametreler gerçek kodlama ile kodlanmış ise; "Gaussian Mutasyon" işlemi kullanılabilir. Gaussian Mutasyon işleminde; gen, mutasyon için seçildiğinde, Gaussian dağılımına göre bir değer belirlenir ve bu değer, genin üzerine eklenir. Gaussian eğrisinin genişliği, bu genin değerinin, pozitif ve negatif değerleridir. Böylece, "Gaussian Mutasyon" işlemi bir gen için uygulandığında, mutasyon oranının Gaussian eğrisi üzerindeki değerine göre genin değeri azaltılabilir veya artırılabilir [29].

Şekil 2.19'da çaprazlama ve mutasyon operatörlerinin çalışma sistemi gösterilmektedir.



Şekil 2.19: Çaprazlama ve mutasyon operatörleri

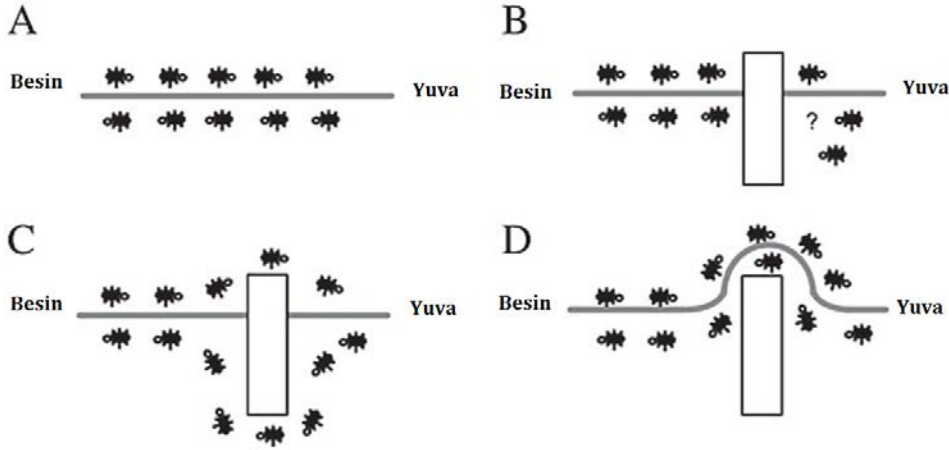
2.6.3. Karınca kolonisi optimizasyonu

ACO algoritması, karmaşık kombinasyonel problemleri çözmek üzere kullanılan ve paralel çalışma becerisine sahip bireylerin deneme yanılma yöntemiyle birlikte çalıştığı bir evrim algoritmasıdır. ACO algoritmasının temeli, mevcut seçimler içerisinde en kısa, en az maliyetli yolun veya çözümün bulunması üzerinedir.

Yapay karıncalar; mevcut alternatif çözümlerden herhangi birisi üzerinden yola başlarlar ve en iyi çözümlerden birisini bulmayı hedeflerler. Her bir yeni karınca, kendisinden önceki karıncanın tecrübelerinden ve değerlendirmelerinden yararlanarak, daha iyi yolları bulmaya çalışır. Zaman içerisinde, daha iyi yollar ve çözümler de mutlaka daha iyi oldukları çözümlerden öne çıkacaklardır [32].

Karıncalar, yuvalarından yiyecek kaynaklarına ve tersine uzanan en kısa yolu, çevresel değişimlere uyum sağlayarak bulabilme yeteneklerine sahiptirler. Yiyecek ve yuva arasındaki en kısa yolu araştırmak için karıncalar tarafından kullanılan ve karıncalar arasında haberleşme imkanı sağlayan temel madde, feromondur. Karıncalar hareket ettikleri yol üzerinde belirli miktarda feromon bırakırlar. Feromon maddesinin daha yoğun olduğu yönleri tercih etme olasılığı, bu maddenin az bulunduğu yönleri tercih etme olasılığına göre daha fazladır. Yuva ve yiyecek arasına bir cisim konulduğunda ise, cisim etrafında daha kısa yolu rastgele seçen karıncalar, uzun yolu tercih edenlere kıyasla, feromon maddesi bağlantı yolunu, çok daha hızlı şekilde oluştururlar.

Bunun sebebi; karıncaların hızlarının aynı olduğu varsayımı altında, birim zamanda kısa yol üzerinden geçen karıncaların, uzun yol üzerinden geçen karıncalardan daha fazla olmasıdır. Kolonideki karıncalar, geçtikleri yola eşit sayıda feromon bırakacakları için, kısa yola bırakılan feromon miktarı daha fazla olmaktadır. Yön tercihi, koku miktarı ile doğru orantılı olduğu için, karıncaların kısa yolu daha yüksek ihtimalle seçmeleri durumu gerçekleşir. Bu olay, aynı zamanda; "otokatalitik pozitif geri besleme işlemi" olarak tanımlanır. Bu durum, Şekil2.20'de gösterilmektedir.



Şekil 2.20: A.Feromon yolunu yuvadan besine takip eden karıncalar; B.Yol üzerine engel konulduğundaki durum; C. Karıncalar engel etrafında iki farklı yoldan dolmaktadır; D.En kısa yol boyunca yeni feromon yolu düzenlenmiştir.

Geliştirilen farklı ACO'ları test etmek için gezgin satıcı probleminin çözümüne odaklanılmıştır. Gezgin satıcı probleminde karıncalar, rastgele seçilen bir şehirden başlayarak bütün şehirleri ziyaret ederler ve geçtikleri yollara feromon bırakırlar.

Bu feromonlar, sonraki karıncaların yollarını belirlemelerinde etkili olur, yani araçlar arasındaki iletişim, ortak sonucu doğurur. Karıncaların her birini, bir düğüme gönderirken, dikkat edilmesi gereken faktör, yarışma şartlarının oluşmasını engellemektir. Aynı anda çalışan karıncalar, yani farklı düğümlerde çalışan karıncalar, feromon ve seçilen yol verilerini tutan global veri yapısını, aynı anda değiştirememelidir.

Bu uygulamada temel amaç, ACO algoritması içerisinde olasılık hesabında kullanılan parametrik alfa (α), beta (β), ro (ρ) değerlerinin en uygunlarını bulmak olduğu için, kolonideki karınca sayısının artırılması, bu değerlerin en uygunlarını bulma olasılığını da arttıracaktır [33].

Problemin başlangıcında, her karınca farklı veya aynı köşelere yerleştirilir.

Bu karıncaların " t " anında hangi komşu düğüm noktasında olacakları aşağıdaki denkleme ait olasılık bağıntısı tarafından belirlenir.

$$P_{ij}^k(t) = \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{i \in N_i} [\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta} \quad \begin{array}{l} \text{kizin verilen bir seçim ise} \\ \text{aksi takdirde} \end{array} \quad (2.61)$$

$\tau_{ij}(t)$: t anında (i, j) köşelerindeki feromon iz miktarı.

η_{ij} : (i, j) köşeleri arasındaki görünürlük değeridir.

Bu değer, problem çözümünde ele alınan kritere göre değişmektedir.

α : problemde feromon izine verilen bağıl önemi gösteren bir parametredir.

β : problemde görünürlük değerine verilen önemi gösteren bir parametredir.

N_i : henüz seçilmemiş olan düğüm noktaları kümesidir.

Karıncalar, bu olasılık bağıntısına göre bir sonraki seçimlerini yaparlar. Problemdaki tüm düğüm noktaları gezildikten sonra, bir tur veya iterasyon tamamlanmıştır.

Bu noktada, aşağıdaki denkleme göre feromon miktarı güncellenir [34].

$$\tau_{ij}(t+n) = (1-\rho)\tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (2.62)$$

ρ : " t " ile " $t+n$ " süreleri arasında buharlaşan feromon iz oranı ($0 < \rho < 1$)

$\Delta\tau_{ij}$: karıncanın bir turu boyunca (i, j) köşesini seçmelerinden dolayı bu köşedeki feromon iz miktarını gösterir. Bu miktar da aşağıdaki bağıntıya göre hesaplanır.

$$\Delta\tau_{ij} = \sum_{k=1}^m \Delta\tau_{ij}^k \quad (2.63)$$

m : toplam karınca sayısı

τ_{ij}^k : k . karıncanın (i, j) köşesine bıraktığı feromon iz miktarı

$\Delta\tau_{ij}^k$, her bir (k) karıncasının herhangi bir (i, j) köşesindeki feromon iz miktarına ne kadarlık katkı yapacağını gösterir.

$$\Delta\tau_{ij}^k = \left\{ \frac{Q}{L_k} \right\} \quad (2.64)$$

Q : sabit bir değer

L_k : k . karıncanın tur uzunluğu

Eğer karınca tur boyunca (i, j) köşesini kullandıysa, yukarıdaki denkleme göre bıraktığı iz miktarı hesaplanır. Aksi halde, iz miktarı sıfır olur. Gerçek karınca kolonilerinde, feromon yoğunluğu buharlaşmadan ve bozulmadan dolayı azalmaktadır. ACO'da

buharlaşmanın etkisi, uygun şekilde tanımlanmış bir buharlaşma kuralının uygulanmasıyla simüle edilmektedir. Örneğin, feromonun yapay gecikmesi sabit bir oran olarak ayarlanabilir. Feromon buharlaşması, araştırmanın erken safhalarındaki yapay karıncaların oluşturduğu düşük kaliteli çözümlerde bırakılmış olan feromonların etkisini azaltır. Feromon buharlaşması, gerçek karıncalarda fark edilir bir etki yapmasa da, yapay karınca kolonilerinde çok yararlı olabilmektedir.

2.7.Sınıflandırma Metotlarının İncelenmesi

Zihinsel görevlerin ayrıştırılması işlemi, her bir göreve ait EEG sinyallerinin özniteliklerinin farklı öznitelik çıkartma yöntemleri kullanılarak eldesi ve bu özniteliklerin, sınıflandırma algoritmaları ile sınıflandırılması şeklindedir.

Sınıflandırma algoritmaları, BCI'nın davranışını doğrudan etkilemektedir. EEG sinyallerinin sınıflandırılması ve analizinde; ANN, istatistiksel yaklaşım, AR model, GMM, ICA, zaman-frekans domeni analizleri, Bayesian Kuadratik, Gizli Markov Modeli (HMM), LDA, SVM gibi metotlar kullanılmaktadır.

Motor imgelemlerinin ayrıştırılması için, spesifik frekans bantlarının gerçek-zamanlı sınıflandırılmasını yapan, ANN'lere dayalı sınıflandırıcı kullanılabilir.

Çok Katmanlı Algılayıcı (MLP) ve statik ağırlıklarının Sınırlı Darbe Cevabı (FIR) filtreleri ile yer değiştirdiği FIR MLP sınıflandırıcıları, EEG dataları üzerinde uygulanmıştır ve yapılan deneylere bağlı olarak FIR MLP'nin daha düşük hataya ve daha yüksek performansa sahip olduğu gösterilmiştir [50]. 2-sınıflı problem için, Karesel Ayırtaç Analizi (QDA) gerçekleştirilebilir [27]. İleri beslemeli ANN, Bayesian sınıflandırıcı, Fisher doğrusal sınıflandırıcı, HMM de doğrusal ve doğrusal olmayan metotları içermektedir.

Doğrusal öğrenme algoritmaları için önerilen bir sınıflandırma yöntemi de, hibrit yinelemeli en küçük kareler kestiricisidir. Bu sınıflandırıcı, nöronları otonom bir şekilde ekleyen dinamik ve optimal yapıya sahiptir. Öz örgütlenmeli bulanık sinir ağı (SOFNN) da; ANN performansının bulanık mantık teorisi kullanılarak geliştirildiği hibrit bir sınıflandırıcı sistemdir. EEG sinyalinin durağan olmayan doğasına uyumludur ve ayrıca karmaşıklığın, doğrusal olmayan sapmaların üstesinden gelebilmektedir [51].

Yüksek boyutlu öznitelik uzayında, SVM'nin LDA'dan daha iyi sınıflandırma performansına sahip olduğu görülmüştür. SVM ile, yüksek boyutlu öznitelik vektörlerine ilişkin sınıflandırmaların yapılması önerilmiştir [5].

Olasılıksal ANN de, alternatif sınıflandırıcı olarak önerilmektedir ve optimal doğrusal olmayan karar sınırları, beyne ilişkin durumların saptanması için uygulanabilir.

2.7.1. Karar destek makinaları

SVM'ler, yüksek sınıflandırma performansı, doğruluğu ve çok sayıda tahmin unsuru ile baş edebilme kabiliyeti sayesinde, hesaplamalı bilimler ve biyoenformatik uygulamalarda oldukça yaygın bir şekilde kullanılmaktadır. SVM, hiperuzay ayrıştırması konseptini, doğrusal olarak ayrılamayan veriler üzerine uygulayıp, tahmin unsurlarını; "öznitelik uzayı", adı verilen yüksek boyutlu uzayda haritalandırarak genişletmiştir.

Karar düzlemi için en mükemmel konumun bulunması; tahmin unsurları, haritalar, doğrusal olmayan dönüşümler yoluyla, doğrusal sınırları kuran çekirdek fonksiyonunun kullanımına dayalı optimizasyon problemidir.

Algoritmadaki en etkili kısım, öznitelik uzayındaki skaler çarpım ve giriş vektörleri açısından kurulan kestirici uzaylarındaki hiperdüzlemin bulunmasıdır. Skaler çarpım; normalize uzunluklara sahip tahmin unsurları değerleri listesine ilişkin, iki vektör arasındaki açının kosinüs değeridir. Bu işlem, yüksek boyutlu uzaydaki vektörler arasındaki uzaklıkların bulunmasını sağlar.

SVM, destek vektörlerini ayıran hiperdüzlemi konumlandırır. SVM sayesinde, parametreler için global optimum, standart optimizasyon yazılımı kullanılarak bulunur. Doğrusal olmayan sınırlar, ekstra bir hesaplama yükü olmaksızın kullanılır. Performans açısından da, oldukça rekabetçidir [82].

SVM, danışmanlı sınıflandırma metodları arasına girmektedir. SVM sınıflandırıcıları;optimal hiperuzayın oluşturulması açısından sırasıyla, doğrusal ayrıştırılabilir olan, tamamen doğrusal ayrıştırılabilir olmayan ve doğrusal ayrıştırılabilir olmayan şeklinde bölümlenirler.

2.7.1.1. Doğrusal ayrıştırılabilir sınıflandırma

$x^{(n)}$ eğitim datasının hem $c^{(n)} = -1$, hem de $c^{(n)} = 1$, sınıflarında elemanlarının olduğunu varsayarsak, bu iki sınıfı birbirinden ayırmak için kullanılacak hiperdüzlem aşağıdaki gibi ifade edilir.


$$wx + b = 0 \quad (2.65)$$

Burada, w vektörü hiperdüzleme diktir ve $\frac{b}{\|w\|}$ de; ayırıcı düzleme orijinden olan dik

uzaklıktır.

SVM algoritması, bütün sınıfların en yakın gözlemlerine olan en uzun mesafeye sahip hiperdüzlemi konumlandırmayı amaçlar. İki sınıf arasındaki marjın maksimize edilmesi işlemi, "Maksimum Marj Sınıflandırıcısı" olarak tanımlanır.

Şekil 2.21'de bu sınıflandırmaya ait bir örnek verilmiştir.



Şekil 2.21: SVM ile yapılan ikili sınıflandırma örneği

Halkalar şeklinde işaretlenmiş karar destek vektörleri, H_1, H_2 çizgilerinin üzerindedirler.

Bu çizgiler aşağıdaki gibi belirlenir.

$$x^{(n)}w + b = +1 \implies H_1 \quad (2.66)$$

$$x^{(n)}w + b = -1 \implies H_2$$

Hiperdüzlem karar destek vektörlerine göre en uzak mesafeye yöneliminin sağlanması için, çizgilerden ayırıcı hiperdüzleme olan uzaklıkların (d_1, d_2) değerlerinin toplamının maksimize edilmesi gereklidir. Optimal ayırıcı hiperdüzlemin bulunması için, karar destek vektörlerine olan uzaklığın maksimize edilmesi ve bunun için de, $\|w\|$ 'nin minimize edilmesi şarttır. Böyle bir karesel programlama, optimizasyon probleminin formülasyonu aşağıdaki gibi oluşturulabilir.

$$\min \left(\frac{1}{2} \|w\|^2 \right) \text{öyle ki} \quad c^{(n)}(x^{(n)}w + b) - 1 \geq 0, \forall_n \quad (2.67)$$

Böyle bir sınırlandırılmış minimizasyon probleminin çözülmesi için de pozitif Lagrange çarpanları kullanılır [11].

$$L(w, b, \alpha) = \min \frac{1}{2} \|w\|^2 - \sum_{n=1}^N \alpha^{(n)} c^{(n)}(x^{(n)}w + b) + \sum_{n=1}^N \alpha^{(n)} \quad (2.68)$$

$\alpha^{(n)}$ kısıtının $\alpha^{(n)} \geq 0 \rightarrow \forall_n$ koşulunu sağlaması için, yukarıda tanımlanmış Lagrange denkleminin w ve b 'ye göre türevinin sıfır olması gereklidir.

2.7.1.2. Tamamen doğrusal ayrıştırılabilir olmayan sınıflandırma

$c^{(n)}(x^{(n)}w + b) - 1 \geq 0, \forall_n$ eşitsizliği ayırıcı hiperdüzlemin yanlış tarafına gidildikçe, artan uzaklıkla birlikte, cezayı da arttıracak şekilde ayarlanan bir tane pozitif gevşeklik değişkeni, $\xi^{(n)}$ eklenerek yeniden düzenlenir.

$$c^{(n)}(x^{(n)}w + b) - 1 + \xi^{(n)} \geq 0, \forall_n \rightarrow \xi^{(n)} \geq 0 \quad (2.69)$$

ve minimizasyon problemi de, aşağıdaki forma dönüştürülür.

$$\min \left(\frac{1}{2} \|w\|^2 + T \sum_{n=1}^N \xi^{(n)} \right) \text{öyle ki} \quad c^{(n)}(x^{(n)}w + b) - 1 + \xi^{(n)} \geq 0, \forall_n \quad (2.70)$$

T , yanlış sınıflandırma üzerinden cezanın atandığı ayarlama parametresidir.

2.7.1.3. Doğrusal olmayan sınıflandırma

Öznelik uzayında, doğrusal olarak ayrıştırılamayan veri setine ait sınıflandırma problemidir. "Kernel Trick" metodu kullanılarak, bu türden bir ayrıştırma yapılabilir. "Kernel Trick"; doğrusal olmayan veri sınıflandırması problemini, doğrusal hale getirilmiş modellerdeki yüksek boyutlu öznelik uzayında haritalandırma işlemidir.

Çekirdek fonksiyonu aşağıdaki gibi verilmiştir.

$$K(x_i, x_j) = (\phi(x_i))^T \phi(x_j) = \frac{\|x_i - x_j\|_2^2}{2a^2} \quad (2.71)$$

Burada $\phi(x_{i,j})$ doğrusal olmayan haritalamadır.

Veri setinin orijinal öznitelik uzayında ayrıştırılması imkansız olsa da, yüksek boyutlu daha farklı bir öznitelik uzayında haritalandırılarak ayrıştırılması mümkün olmaktadır. Radyal temelli, polinomyal, sigmoid, matern kernel vb. birçok farklı çekirdek fonksiyonu vardır.

2.7.2. Yapay sinir ağları

İlk yapay sinir ağı modeli, 1943 yılında, McCulloch ve Pitts tarafından gerçekleştirilmiştir. İnsan beyninin hesaplama yeteneğinden ilham alarak, elektrik devreleri ile basit bir sinir ağı modellemiştir.


Genel olarak, insan beyninin ya da merkezi sinir sisteminin çalışma prensiplerini taklit eden bilgi işleme yapılarıdır. Öğrenme yolu ile yeni bilgiler türetme yeteneğini otomatik olarak gerçekleştirebilmek amacı ile geliştirilmiştir. Bu konu üzerindeki çalışmalar, beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar bilimleri alanında uygulanması ile başlamış ve birçok alanda kullanılır hale gelmiştir. ANN, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem biriminden meydana gelen sistemlerdir. Bir işlem birimi, diğer nöronlardan gelen sinyalleri alır ve bunları birleştirerek dönüştürür.

Bu işlem sonucunda, sayısal bir değer elde edilir. Genelde, işlem birimleri gerçek nöronlara karşılık gelirler ve bir ağ yapısı ile birbirlerine bağlanarak, katmanlar şeklinde düzenlenirler. Beynin bilgi işleme yöntemine uygun olarak, ANN; bir öğrenme sürecinden sonra bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi depolama ve genelleme yeteneğine sahip paralel işlemcidir. Öğrenme süreci, hedeflenen amaca ulaşmak için ANN ağırlıklarının güncellenmesini sağlayan çeşitli öğrenme algoritmalarını içerir. ANN'ler karmaşık problemleri çözebilme kapasitesine sahiptirler.

Süper bilgisayarların bile, obje tanıma, karar verme işlemlerinde canlı organizmalara göre oldukça yavaş kaldığı ve sıkça da, uygun olmayan sonuçlar ürettiği gözlenmektedir. Doğadaki canlıların görsel tanıma yeteneğinin bilgisayarlarla karşılaştırılmayacak kadar güçlü olduğu, yani doğru ve hızlı kararlar ürettiği gözlenmiştir. Bu yüzden, karar verme işlemlerinde, sinir hücrelerinde gözlenen yapılar taklit edilmeye başlanmıştır ve modeller ileri ve geri beslemenin birlikte ele alındığı genel amaçlı ANN'lerikapsayacak şekilde genişletilmiştir. Doğrusal olmayan karmaşık yapıların eğitiminde, her yeni ağ yapısı için farklı bir eğitim algoritması kullanılmaktadır.

Bu tezde, sınıflandırma amacıyla kullanılan ANN'lerin yapıları detaylı bir şekilde incelenecektir. Genel olarak ağlar; bir uzaydan, diğer bir uzaya geçiş amacıyla kullanılır. Eğitim kümesindeki vektörler kullanılarak, iki uzay arasındaki doğrusal olmayan transfer fonksiyonuna adım adım yaklaşılar. ANN'lerin sınıflayıcı biçimde kullanılması durumunda, transfer fonksiyonunun çıkışı, ikili kodlar ile temsil edilir. ANN'lerin sınıflandırıcı olarak kullanılmasının nedenleri arasında;

- (i) eğitim kümesindeki vektörler kullanılarak sonuca adım adım yaklaşılması,
- (ii) eğitim kümesinde bulunmayan giriş vektörlerine uygun cevabın üretilmesi, yani genelleme yeteneği,
- (iii) fiziksel anlamda gerçekleştirilebilir olması,
- (iv) ağların paralel yapıya sahip olduğu için sınıflandırma işlemine hızlı cevap üretmesi,
- (v) kompleks sınıfsal dağılımları temsil edebilme yeteneği gelmektedir.



Şekil 2.22: McCulloch&Pitts nöron modeli

Şekil 2.22'de McCulloch ve Pitts'in geliştirdiği nöron modeli verilmiştir. Her nöron, iki kısımdan meydana gelir, birincisi ağ fonksiyonu iken, diğeri de aktivasyon fonksiyonudur. Ağ fonksiyonu sinir ağının girdilerinin $\{y_j; 1 \leq j \leq N\}$ nöron içinde nasıl birleştirildiğini belirler [39].

Ağırlıklandırılmış doğrusal kombinasyon, aşağıdaki formüle göre uyarlanmıştır.

$$u = \sum_{j=1}^N \omega_j y_j + \theta \quad (2.72)$$

$\{\omega_j; 1 \leq j \leq N\}$ sinaptik ağırlıklar olarak bilinmektedir. θ bias ya da eşik olarak adlandırılır.

Nöronun çıktısı olan a_i , ağın girdisi u_i ile ilişkilidir ve aşağıda gösterilen doğrusal ya da doğrusal olmayan aktivasyon fonksiyonuna bağlıdır.

$$a = f(u) \quad (2.73)$$

Farklı ANN modellerinde, farklı aktivasyon ve ağ fonksiyonları kullanılır ve bu fonksiyonlar Tablo 2.1'de özetlenmiştir.

Tablo 2.1: Ağ fonksiyonları ve nöron aktivasyon fonksiyonları

Ağ Fonksiyonları	Formüller	Yorumlar
Doğrusal	$u = \sum_{j=1}^N w_j y_j + \theta$	En genel kullanım şekli
Yüksek mertebeden (2. derece formül)	$u = \sum_{j=1}^N \sum_{k=1}^N w_{jk} y_j y_k + \theta$	u_i girdi değişkenine ait yüksek dereceden polinomial terimlerin ağırlıklandırılmış doğrusal kombinasyonlarıdır. Girdi terimlerinin sayısı N^d d polinom derecesidir.
Delta ($\Sigma - \Pi$)	$u = \prod_{j=1}^N w_j y_j$	Nadiren kullanılır

Aktivasyon Fonksiyonu	Formül $a = f(u)$	Türevler $\frac{df(u)}{du}$	Yorumlar
Sigmoid	$f(u) = \frac{1}{1+e^{-u/T}}$	$f(u)[1 - f(u)]/T$	Yaygın olarak kullanılır ve türevi doğrudan hesaplanabilir
Hiperbolik tanjant	$f(u) \tanh\left(\frac{u}{T}\right)$	$(1 - [f(u)]^2) / T$	$T =$ sıcaklık parametresi
Ters tanjant	$f(u) = \frac{2}{\pi} \tan^{-1}\left(\frac{u}{T}\right)$	$\frac{2}{\pi T} \cdot \frac{1}{1+(u/T)^2}$	Daha az sıklıkta kullanılır
Eşik değeri	$f(u) = \begin{cases} 1 & u > 0; \\ -1 & u < 0. \end{cases}$	Türevi bulunmamaktadır $u = 0$	
Gaussian radyal tabanlı	$f(u) = \exp[-\ u - m\ ^2/\sigma^2]$	$-2(u - m) \cdot f(u)/\sigma^2$	Radyal tabanlı sinir ağları için kullanılır ve parametreleri spesifik olarak seçilir
Doğrusal	$f(u) = au + b$	a	

2.7.2.1.Yapay sinir ağlarının genel özellikleri

Doğrusal olmama;

ANN'nin temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla, hücrelerin birleşmesinden meydana gelen ANN de doğrusal değildir ve bu özellik, bütün ağa yayılmış durumdadır.

Öğrenme;

ANN'nin istenen davranışı göstermesi için ağırlıklarının ayarlanmasına ihtiyaç vardır. Bu aynı zamanda, hücreler arasında doğru bağlantıların yapılmasını gerekli kılar. Yüksek karmaşıklık düzeyi nedeniyle, bağlantı ve ağırlıklar önceden ayarlı olarak verilmez. Bu yüzden, hedeflenen davranışı gösterecek şekilde ilişkili olduğu problemden aldığı eğitim verilerini kullanarak, problemi öğrenir.

Genelleme;

ANN, ilişkili olduğu problemi öğrendikten sonra, test verileri için de hedeflenen tepkiyi üretebilmelidir. Eğitim sürecinde verilmeyen giriş sinyalleri için dahi, sistemle aynı davranışı gösterebilir.

Adaptasyon;

ANN ilişkili olduğu probleme ait değişikliklere göre ağırlıklarını günceller. Belirli bir problemi çözmek için eğitilen ANN, probleme ait değişimlere göre tekrar eğitilir. Bu özelliğinden dolayı ANN, adaptif örnek tanıma, sistem tanıma ve sinyal işleme gibi alanlarda etkili olarak kullanılmaktadır.

Hata Toleransı;

ANN, çok sayıda hücrenin farklı biçimlerde bağlanmasından meydana geldiğinden paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine yayılmıştır. Bu nedenle, eğitilmiş bir ANN'nin bağlantılarının, ve/veya bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, hataları tolere etme kapasiteleri oldukça gelişmiştir.

Donanım ve Hız:

Büyük ölçekli entegre devre teknolojisi ile gerçekleşir. Bu özelliğinden dolayı, ANN'nin hızlı bilgi işleme yeteneği artar ve gerçek-zamanlı uygulamalarda tercih edilir.

ANN'lerin; özçalışma, özorganizasyon, ilişkilendirilmiş hafıza, paralel işleme ve dağıtılmış depolama vb. karakteristikleri vardır. ANN'lerinden küçük birimi yapay nörondur. Biyolojik nöron modeline benzerdir ve kendi aritmetik modülüne sahiptir.

Yapay sinir ağı; temel olarak girdi sinyali ya da şablon vektörünü $x_j = (x_1, x_2, \dots, x_N)$ alan giriş nodları kümesi, ağırlıklar $W_{ij} = (w_{11}, w_{12}, \dots, w_{1n}, w_{21}, \dots, w_{m1}, \dots, w_{mn})$ şeklinde ifade edilen sinaptik bağlantı kümesi ve nöronun çıkışını, toplam sinaptik girişe bağlayan aktivasyon fonksiyonundan meydana gelir.

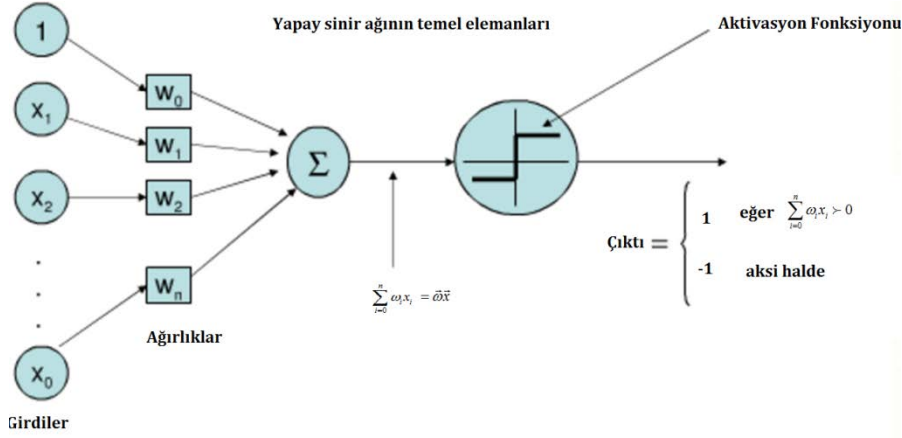
ANN, tasarım, eğitim ve test olacak şekilde üç faza sahiptir. Tasarım fazında, ağız mimarisi tanımlanır. Bunlar sırasıyla; girdi, çıktı ve katman sayıları, aktivasyon fonksiyonunun cinsidir. Eğitim fazında, öğrenme algoritması aracılığı ile, ağız bağlantı elemanları olan ağırlıklar belirlenir. En sonunda ise, modellenmiş yapay sinir ağının eğitim fazında elde edilmiş sabit parametrelerine ilişkin performans test edilir.

Geri yayımlı yapay sinir ağı; giriş, gizli, çıkış olacak şekilde üç tür katmandan meydana gelmiştir. Girdi şablonu ile, çıktı şablonu arasındaki ilişki; doğrusal olmayan fonksiyona sahip öğrenme algoritması ile elde edilir.

2.7.2.2. Perceptron modeli

Biyolojik sinir sistemine ait nöron, dendrit, hücre gövdesi, akson ve sinapslara yapay sinir sisteminde sırasıyla, işlemci eleman, toplama fonksiyonu, transfer fonksiyonu, yapay nöron çıkışı ve ağırlıklar karşılık gelir. İşlem elemanı, transfer fonksiyonu ve öğrenme ile ilgili kavramların daha iyi anlaşılması için; ANN'lerde en temel yapı olan Rosenblatt tarafından geliştirilmiş Perceptron'u inceleyelim.

'Perceptron', Şekil 2.23'te gösterilen birden fazla girişi ve en az bir çıkışı olan bir transfer fonksiyonu ve giriş sayısı kadar yerel bellek elemanına sahip, en basit yapıdaki yapay sinir ağıdır.



Şekil 2.23: Perceptron modeli

'Perceptron'un matematiksel ifadesi aşağıda verilmiştir.

$$u(\underline{x}) = \omega_0 + \sum_{i=1}^n \omega_i x_i \quad (2.74)$$

$u(\underline{x})$; burada ağ fonksiyonudur ve çıktı $y(\underline{x})$ de ağ fonksiyonuna bağlı bir aktivasyon fonksiyonu aracılığı ile, aşağıdaki gibi elde edilir.

$$y(\underline{x}) = \begin{cases} 1, & u(\underline{x}) \geq 0 \\ 0, & u(\underline{x}) < 0 \end{cases} \quad (2.75)$$

Perceptron nöron modeli tespit ve sınıflandırma amacıyla kullanılır. Ağırlık vektörü; $\underline{\omega} = (\omega_1, \omega_2, \dots, \omega_n)$ belirli bir hedefe ulaşmak için gerekli şablonu ortaya koyar.

Eğer, giriş öznitelik vektörleri ile, ağırlık vektörlerinin iç çarpımı belirli bir eşik değerini aşarsa, o zaman çıktı +1 değeri alır. Perceptron modelinin uygulanabilmesi için ağırlık vektörlerinin belirlenmesi gereklidir.

2.7.2.3. Yapay sinir ağlarında öğrenme

Giriş ve çıkış arasındaki ilişkiyi istenilen şekilde oluşturmak için, değişik eğitim algoritmaları kullanılır. Literatür incelendiğinde, her ağ için farklı bir eğitim algoritmasının kullanıldığı gözlemlenmektedir. Bu algoritmalar, öğrenme yöntemlerine göre aşağıdaki gibi sınıflandırılabilir:

a) Salt eylemci: İç yapı çevre ile etkileşim altında değişmez

b) Öğrenen

b.1) Denetimsiz öğrenme

b.2)Denetimli öğrenme

b.2.1)Eğitici doğru sonucu söyler


b.2.2)Eğitici sadece ödül-ceza verir

Genel olarak, bir yapay sinir ağının öğrenmesi, çevreden ve varsa eğiticiden aldığı girişler uyarınca (çoğunlukla belirli bir amacı daha iyi yapabilmek için), giriş-çıkış işlevini, iç yapısını uyarlayarak değiştirmesi olarak tanımlanır. İç yapıdaki değişiklikler; yeni bağlantılar oluşturmak, varolan bağlantıları yok etmek veya varolan bağlantıların ağırlıklarını değiştirmek şeklinde gerçekleşir.

Öğrenen denetimsiz ANN'lere örnek olarak; neocognitron, yarışmalı öğrenme (Kohonen, SOM), adaptif rezonans teorisi verilebilir. Öğrenen denetimli ANN'lere örnek olarak da; perceptron, adaline, çok katmanlı ağ, içerik adreslemeli bellek, Büyü ve Öğren (GAL), Kısıtlı Coulomb Enerji (RCE) verilebilir. Salt eylemci ANN'ler arasında ise, Retina ve Hopfield ağları bulunmaktadır.

2.7.2.4.Çok katmanlı perceptron modeli

ANN'ler, katman olarak isimlendirilen alt kümeler içinde aynı yapıda işlem elemanlarına sahiptir. Bu alt kümeler içindeki tüm işlem elemanları, aynı transfer fonksiyonunu kullanır. Şekil 2.24'te n katmana sahip bir ağ gösterilmiştir. Aynı katman içindeki işlem elemanları, birbirleriyle veya diğer katmanlardaki elemanlar ile bağlantı oluşturabilirler.



Şekil 2.24: Çok katmanlı perceptron modeli


Çok katmanlı ağların eğitiminde, başlıca üç temel problemle karşılaşmaktadır. (i) Eğitim işlemi uzun zaman almaktadır, (ii) düğüm ağırlıklarının başlangıç değeri, ağın eğitimini olumsuz yönde etkileyebilmekte ve çoğunlukla, ağ ağırlıklarının yerel optimuma yakınsadığı gözlemlenmektedir, (iii) katmanlardaki düğüm sayısının önceden doğru kestirilmesi mümkün değildir, genellikle birkaç denemeden sonra düğüm sayıları belirlenebilmektedir. Bu sorunlar, eğitim kümesinin büyümesi ile, daha da belirgin olmaya başlamaktadır. Eğitim kümesinin az sayıda vektör içermesi, ağın genelleme özelliğinin düşmesine sebep olacaktır.

2.7.2.5. Geri yayılım algoritması

Geri beslemeli ANN'de, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle, geri besleme işlemi bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi, katmanlar arasındaki hücreler arasında da olabilir. Bu yapı ile geri beslemeli ANN, doğrusal olmayan dinamik bir karakteri yansıtır. Bu öğrenme algoritması, sürekli türevlenebilir aktivasyon fonksiyonlarına sahip, çok katmanlı ileri beslemeli ağlara uygulanır.

Ağa ait ağırlıklar, geri yayımlı öğrenme algoritması ile güncellenerek, verilen girdi şablonlarını doğru bir şekilde sınıflandırır.

Şekil 2.25'te geri yayılım algoritmasına ilişkin şema görülmektedir.



Şekil 2.25: 3 Katmanlı geri yayılım ağı

Verilen bir girdi şablonu x için, gizli katmandaki "q" nöronu aşağıdaki gibi bir net girdi alır.

$$V_q = \sum_{j=1}^m v_{qj}x_j \quad (2.76)$$

ve "q" nöronu için aşağıdaki çıktı üretilir.

$$z_q = \varphi(V_q) = \varphi\left(\sum_{j=1}^m v_{qj}x_j\right) \quad (2.77)$$

$$\varphi(x) = \frac{1}{1+e^{-x}}$$

φ , "q" nöronuna ait aktivasyon fonksiyonudur.

$$z_q = \frac{1}{1+e^{-V_q}} \quad (2.78)$$

Çıktı katmanındaki "i" nöronu için net girdi;

$$V_i = \sum_{q=1}^n \omega_{iq}z_q \quad (2.79)$$

"i" nöronu için aşağıdaki çıktı üretilir

$$y_i = \varphi(V_i) = \varphi\left(\sum_{q=1}^n \omega_{iq}z_q\right) \quad (2.80)$$

$$\varphi(x) = \frac{1}{1+e^{-x}}$$

φ , i nöronuna ait aktivasyon fonksiyonudur.

$$y_i = \frac{1}{1+e^{-V_i}} \quad (2.81)$$

Yukarıdaki denklemler, girdi sinyallerinden nöron katmanları boyunca olan ileri yayılımı göstermektedir.

İkinci safhada, hata sinyalleri ve geri yayılım algoritması dikkate alınacaktır.

Öncelikle maliyet fonksiyonu tanımlanır.

$$E = \frac{1}{2} \sum_{i=1}^n e_i^2 \quad (2.82)$$

Daha sonra gradyan çöküş metoduna göre, gizli katmandan çıktı bağlantılarına olan ağırlıklar güncellenir;

$$\Delta\omega_{iq} = -\eta \frac{\partial E}{\partial \omega_{iq}} \quad (2.83)$$

$\frac{\partial E}{\partial \omega_{iq}}$ için zincir kuralı uygulanırsa;

$$\Delta\omega_{iq} = -\eta \left[\frac{\partial E}{\partial e_i} \frac{\partial e_i}{\partial y_i} \right] \left[\frac{\partial y_i}{\partial V_i} \right] \left[\frac{\partial V_i}{\partial \omega_{iq}} \right] = \eta e_i (\varphi'(V_i)) z_q \quad (2.84)$$

$$\Delta\omega_{iq} = \eta \delta_{oi} z_q$$

Burada δ_{oi} , yerel gradyan hata sinyalidir ve alt indisi çıktı katmanındaki "i." nodu gösterir.

Hata sinyali aşağıdaki gibi tanımlanır

$$\delta_{oi} = -\frac{\partial E}{\partial V_i} = e_i \varphi'(V_i) \quad (2.85)$$

"i" nöronuna ait aktivasyon fonksiyonun türevi

$$\varphi'_i(x) = \frac{1}{e^x(e^{-x}+1)^2} = \varphi_i(1 - \varphi_i) \quad (2.86)$$

Girdi katmanından, gizli katmana ait bağlantılardaki ağırlıkların güncellenmesi için, gradyan çöküş metodu ile birlikte zincir kuralını uygulamamız gerekmektedir.

Girdi katmanı j'den gizli katmandaki q nöronuna olan ağırlık bağlantıları üzerindeki güncelleme denklemleri aşağıdaki gibi elde edilir.

$$\Delta v_{qj} = -\eta \frac{\partial E}{\partial v_{qj}} \quad (2.87)$$

$$\Delta v_{qj} = -\eta \left[\frac{\partial E}{\partial V_q} \right] \left[\frac{\partial V_q}{\partial v_{qj}} \right] = -\eta \left[\frac{\partial E}{\partial z_q} \right] \left[\frac{\partial z_q}{\partial V_q} \right] \left[\frac{\partial V_q}{\partial v_{qj}} \right] \quad (2.88)$$

Her hata teriminin $[d_i - y_i]$, z_q 'nun bir fonksiyonu olduğu açıktır.

Zincir kuralı uygulandığında;

$$\Delta v_{qj} = \eta \left[\sum_{i=1}^n e_i \varphi'(V_i) \omega_{iq} \right] \varphi'(V_q) x_j \quad (2.89)$$

Aşağıdaki formda yeniden düzenlendiğinde;

$$\Delta v_{qj} = \eta \left[\sum_{i=1}^n \delta_{oi} \omega_{iq} \right] \varphi'(V_q) x_j = \eta \delta_{hq} x_j \quad (2.90)$$

Burada δ_{hq} , gizli katmandaki nöron q 'ya ait yerel gradyan hata sinyalidir ve aşağıdaki gibi tanımlanır

$$\delta_{hq} = -\frac{\partial E}{\partial v_q} = \varphi'(V_q) \sum_{i=1}^n \delta_{oi} \omega_{iq} \quad (2.91)$$

Nöron q 'ya ait aktivasyon fonksiyonunun türevi;

$$\varphi'_q = \frac{1}{e^{x_q}(e^{-x_q}+1)^2} = \varphi_q(1 - \varphi_q) \quad (2.92)$$

2.7.3. K en yakın komşuluk

K En Yakın Komşuluk (KNN) algoritması, bir tür danışmanlı sınıflandırma algoritmasıdır. Test noktalarına ait sınıflandırma test noktalarından, K eğitim noktalarına olan öklidyen uzaklığın belirlenmesi şeklinde gerçekleşir.


Sırası ile, N ve P adet eğitim ve test noktamızın olduğu varsayalım.

$x^{(n)}$, ($n = 1, \dots, N$) eğitim kümesi ve $y^{(l)}$, ($l = 1, \dots, P$) test kümesi olsun. Bir tane test noktası $y^{(l)}$, ve tüm eğitim kümesi $x^{(n)}$, arasındaki öklidyen uzaklık hesaplanır.

$$\begin{aligned} d^{(1)} &= \sqrt{(\mathbf{x}^{(1)})^2 - (\mathbf{y}^{(1)})^2} \\ d^{(2)} &= \sqrt{(\mathbf{x}^{(2)})^2 - (\mathbf{y}^{(2)})^2} \\ &\cdot \\ &\cdot \\ &\cdot \\ &\cdot \\ d^{(n)} &= \sqrt{(\mathbf{x}^{(n)})^2 - (\mathbf{y}^{(n)})^2} \end{aligned} \quad (2.93)$$

Uzaklıklar kendi içinde sıralanır ve K en yakın eğitim noktası $y^{(l)}$ 'in sınıflandırmasını belirler. K 'ya ait optimal değer spesifik veri setine bağlıdır. Eğer K değeri çok yüksek ise, düzeltme riski ve sınıfları ayırmada zorluk meydana gelir. Eğer K değeri çok küçük seçilirse, spesifik veri setinin şablonuna aşırı uyma gerçekleşir. K değerinin optimal bir şekilde belirlenmesi için; “yuvalanmış çapraz doğrulama” metodu uygulanabilir. K 'nın optimal değeri, en küçük eğitim sınıflandırma hatasına sahip olan değerdir.

KNN algoritmasının avantajı, yoğunluk fonksiyonu hakkındaki apriorik bilgiye sahip olunmasını gerektirmemesidir [11]. KNN algoritması yapılarak gerçekleştirilen sınıflandırma Şekil 2.26'da gösterilmiştir.



Şekil 2.26: KNN algoritmasına bağlı olarak yapılan sınıflandırmanın şematik gösterimi

Şekil 2.26'da gösterilen siyah kare, test noktasıdır. Mavi ve kırmızı renkteki şekiller de sırasıyla, birinci ve ikinci sınıfa ait eğitim verileridir.

2.7.4.Sade Bayesian sınıflandırıcı

NB metodu olasılıksal tabanlıdır ve Bayes Teoremi üzerine kurulmuştur. Ardıl olasılık (posterior probability), öncül olasılık (prior probability) ve olabilirlik (likelihood) kullanılarak aşağıdaki gibi hesaplanır.

$$p(c | x) = \frac{p(x | c)p(c)}{p(x)} \quad (2.94)$$

Burada $x = x_1, x_2, \dots, x_k$, k sayıda öznitelik ve " x " de öznitelik vektörü olsun. " c " de sınıf değişkeni " C "'ye ait değer olsun. Ardıl dağılım " C " sınıfına ait olan öznitelik vektörlerinin olasılığıdır. Öznitelikler bağımsız olduklarından dolayı, ardıl olasılık, koşullu bağımsızlık özelliğine bağlı olarak modifiye edilir.

$$p(x_1, x_2, \dots, x_k | c) = p(x_1 | c)p(x_2 | c) \dots p(x_k | c) = \prod_{i=1}^k p(x_i | c) \quad (2.95)$$

$$p(c | x_1, x_2, \dots, x_k) = \frac{p(c) \prod_{i=1}^k p(x_i | c)}{p(x_1, x_2, \dots, x_k)} \quad (2.96)$$

Verili bir öznitelik vektörü için en yüksek olasılığı veren sınıfa ait atama yapılır.

A ve B şeklindeki iki sınıfa ait durumda;

$$NBC = \frac{P(C=A | x)}{P(C=B | x)} = \frac{p(C=A)}{p(C=B)} \prod_{i=1}^k \frac{p(x_i | C=A)}{p(x_i | C=B)} \quad (2.97)$$

Burada, öznitelik vektörü, eğer $NBC > 1$ ise, 1.sınıfa ($c = A$) atanır. Eğer $NBC < 1$ ise, ikinci sınıfa ($c = B$) atanır.

2.7.5. Gaussian karışım modeli

Gaussian Karışım Modeli (GMM), verinin bir veya daha çok Gauss dağılımının ağırlıklı bileşimi olarak gösterilmesine dayalı istatistiksel yöntemdir. Karışım modeli elde edilirken, ortalama vektör, kovaryans matrisi ve karışım ağırlıkları parametreleri kullanılır. M bileşenli bir GMM aşağıdaki denklem ile ifade edilir [70].

$$p(x | \lambda) = \sum_{k=1}^M \omega_k g(x | \mu_k, \Sigma_k) \quad (2.98)$$

x , D boyutlu ölçümlere veya özelliklere dayalı olan sürekli değerli veri vektörü, ω_k , karışım ağırlıkları ve $g(x | \mu_k, \Sigma_k)$, ($k = 1, \dots, M$) bileşen yoğunluklarıdır.

Her bir bileşen yoğunluğu, D boyutlu Gauss fonksiyonu formundadır.

$$g(x | \mu_k, \Sigma_k) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_k|^{\frac{1}{2}}} e^{\{-\frac{1}{2}(x-\mu_k)' \Sigma_k^{-1} (x-\mu_k)\}} \quad (2.99)$$

μ_k , ortalama vektör, Σ_k kovaryans matrisidir. GMM'de karışım ağırlıklarının toplamı 1'e eşit olmalıdır ($\sum_{k=1}^M \omega_k = 1$). GMM'yi oluşturan parametreler $\lambda = \{\mu, \Sigma, \omega\}$ olarak ifade edilir.

GMM sınıflayıcıları, danışmansız öğrenme kategorisinde yer almaktadır. GMM eğitiminde temel amaç λ' 'yi, eğitim verilerinin dağılımına en iyi uyacak değerlere yaklaştırmaktır [71].

Maksimum olabilirlik tahmin tekniği ile, beklentinin maksimumlaştırılması algoritması birlikte kullanılarak, GMM parametreleri en doğru şekilde tahmin edilebilir. Beklentinin maksimumlaştırılması algoritması, temel olarak dört adımdan meydana gelmektedir [72,73].

Birinci adım, λ değerleri için başlangıç değerinin belirlenmesidir. Sonraki adımların iyi sonuç vermesi için, başlangıç değerlerinin ideal değerlere yakın seçilmesi gereklidir. İkinci adım ise, beklenti adımındır. Bu adımda, öncelikle bileşen yoğunluğu hesaplanır ve elde edilen sonuç, aşağıdaki denklemde yerine konulur.

$$\alpha_{t,j} = \frac{\omega_j g(x_t | \mu_k, \Sigma_k)}{\sum_{k=1}^M \omega_k g(x_t | \mu_k, \Sigma_k)}, j = 1, \dots, M, t = 1, \dots, N \quad (2.100)$$

α ifadesi t noktasının j .Gauss da olma ihtimalini gösterir. Maksimumlaştırma adımı olan son adımda ise, λ parametrelerinin güncelleştirilmesi gerçekleştirilir.

Parametre güncelleştirilmesi, aşağıdaki denklemlerle elde edilir ve eğitim istenilen seviyeye gelene kadar, adımlar döngü içerisinde tekrar edilir.

$$\omega'_j = \frac{1}{N} \sum_{k=1}^N \alpha_{k,j} \quad (2.101)$$

$$\mu'_j = \frac{\sum_{k=1}^N \alpha_{k,j} x_k}{\sum_{k=1}^N \alpha_{k,j}} \quad (2.102)$$

$$\Sigma'_j = \frac{\sum_{k=1}^N \alpha_{k,j} (x_k - \mu'_j)(x_k - \mu'_j)^T}{\sum_{k=1}^N \alpha_{k,j}} \quad (2.103)$$

Bu algorithmada, eğitim sonunda yerel minimumun bulunması sağlanır.

2.8.BCI Kontrol Stratejilerinin İncelenmesi

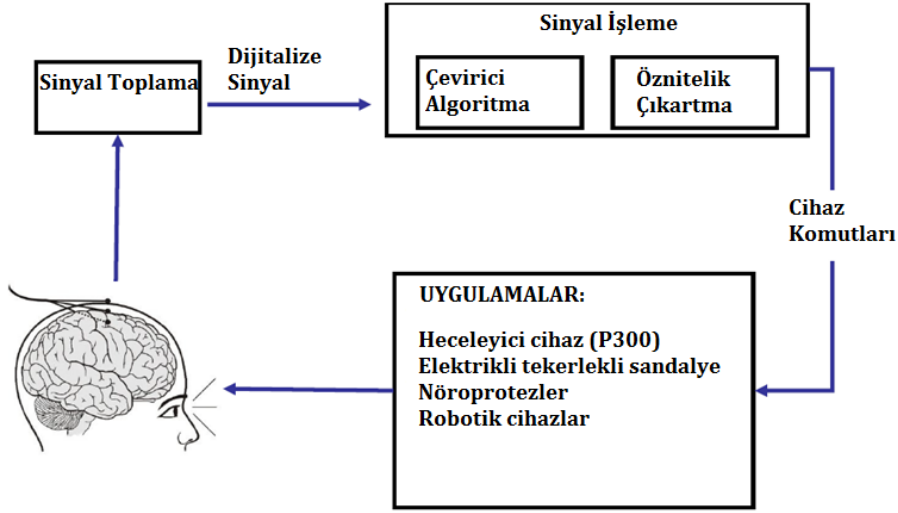
BCI sinyallerin toplanması, işlenmesi, şablon tanıma ve kontrol sistemleri bileşenlerinden meydana gelir. BCI; sinir ve kas hareketleri tarafından üretilen elektrofizyolojik sinyallerin bilgisayar donanımı ve yazılımı aracılığı ile, bir dışsal makinayı eylemek için kontrol sinyallerine dönüştürülme mekanizmasıdır.

Yüksek karmaşıklık seviyesine sahip EEG sinyalinin içerisindeki bilgi açığa çıkartılır. Bu işlem, yürütülen zihinsel görevlere ait kaydedilen EEG sinyallerinin özniteliklerinin çıkartılması ve ardından bu öznitelik kümelerine ilişkin her bir zihinsel görevin sınıflandırılması şeklinde gerçekleştirilir. BCI sisteminin geliştirilmesi sonucunda spesifik EEG sinyali ile bağlantılı olan zihinsel görev tespit edilmiş olur. Invazif olmayan metotlar arasında, EEG tabanlı BCI kullanımının, maksimum gözetlenebilir frekans aralığının ve spasyal çözünürlüğünün düşük olması gibi dezavantajlarına rağmen; ekonomik açıdan efektif olması ve yüksek zamansal çözünürlük sağlaması gibi avantajları vardır. BCI sisteminin performansını ve efektifliğini ölçmek için birçok yöntem ileri sürülmüştür. Bunlar, genellikle sınıflandırma doğruluğunun ve bilgi aktarım oranının ölçülmesini içermektedir.

EEG sinyalleri, belirli bir oranda örneklenir. BCI çıktıları yönelimsel kontrol durumu veya kontrolün olmadığı durum olmak üzere iki işlemsel duruma ayrılırlar.

Her örneklemin, bu iki durumdan hangisine ait olduğu sistem tarafından belirlenir. Doğru Pozitif Oran (TPR), yönelimsel kontrol durumları arasında doğru sınıflandırılan durumların oranı iken, Yanlış Pozitif Oran (FPR) ise, yanlış sınıflandırılan, kontrolün olmadığı durumların oranıdır [26].

2.8.1.İnvazif olmayan BCI tasarımı



Şekil 2.27: İnvazif olmayan BCI akış diyagramı

Şekil 2.27'de görüldüğü üzere, EEG tabanlı BCI, kullanıcının beyni ve kontrol edilen cihaz arasında kapalı döngüsel etkileşim içerir.

Zihinsel görevlere ilişkin beyin aktivitelerinin ölçüldüğü, sinyal toplama modülü vardır. En düşük seviyede, bu sinyaller nöronal ateşleme frekansında kodlanan bilgileri taşırlar. Kafatasına yerleştirilen EEG elektrotları ile, ancak sınırlı tipte ve sayıda nöronal grup aktivitelerine erişilebilmektedir. Buna rağmen, zihinsel göreve ait çıkarsama yapmaya yetecek seviyede bilgi, karışık ve çapraşık biyoelektriksel EEG potansiyellerinde içerilmektedir. BCI, sahip olduğu çevirici algoritma ile, zihinsel görev ve beyin sinyallerine ilişkin bilgiyi çözümlenmekte ve hangi eylemin yapıldığına karar vermektedir. Bu konuda en yaygın paradigmlar; Kararlı Hal Görsel Uyandırılmış Potansiyeller (SSVEP), Yavaş Kortikal Potansiyeller(SCP), zihinsel görevler, ERD/ERS ve P300'den meydana gelmektedir [19].

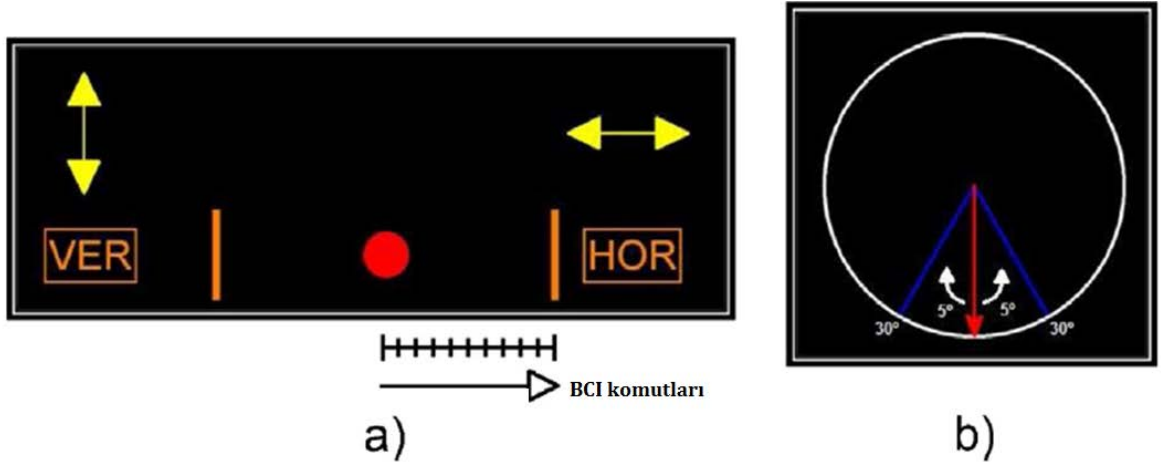
Tasarlanacak olan BCI'nın temel amacı, kullanıcının gerçekleştirdiği zihinsel görevleri doğru bir şekilde sınıflandırmasıdır. Burada, performans değerlendirmesi için çeşitli metrikler önerilmiştir. BCI'nın performansı, ayrık seçimlere odaklanıldığında, "doğru seçim/dakika" olmaktadır.

Kontrol sinyallerini çıkartabilmek için, μ ritmindeki değişikliklere dayanan büyük oranda harekete ilişkin öznitelikler tercih edilmektedir. Zihinsel görevlere ait özniteliklerin çıkartılmasında çok çeşitli algoritmalara dayalı teknikler belirlenmektedir.

Zihinsel görevler icra edilirken, farklı beyin bölgelerine ait spasyal lokasyonlar aktive olmaktadır. Örneğin, dil işlemeye ait bir düşünsel faaliyet sol temporal bölgede yüksek bir aktiviteye sebep olurken, küp döndürme imajinasyonu gibi spasyal işlemlere ait düşünsel faaliyetler, sağ hemisferik aktivasyonlarla sonuçlanır.

BCI testlerinin performansı aşamasında, genellikle hiyerarşik ve yönsel kontrol stratejileri kullanılmaktadır. Bu kontrol stratejileri, hatalar ve harcanan zamanlar açısından birbirlerine göre kıyaslanmaktadır. Hiyerarşik kontrol, hedefe yaklaşımda daha doğru sonuç vermesine karşın, yönsel kontrolden daha yavaş tepki vermektedir.

Şekil 2.28'de hiyerarşik ve yönsel kontrol stratejilerine ait arayüzler gösterilmektedir.

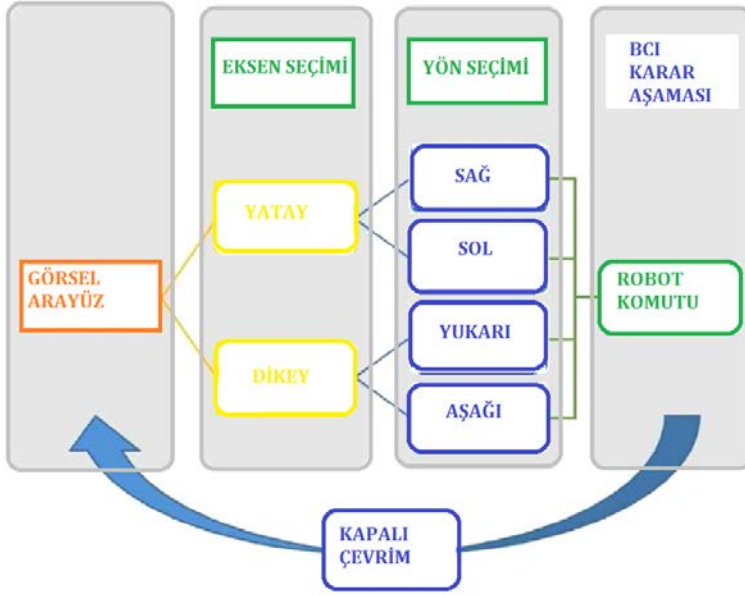


Şekil 2.28: a) Hiyerarşik kontrol arayüzü b) Yönsel kontrol arayüzü

2.8.2. Hiyerarşik kontrol stratejisi

Bu kontrol stratejisinde, objenin hareketi, iki eksen boyunca sınırlandırılmıştır. Her bir kontrol komutu, sırasıyla; sağ, sol, yukarı ve aşağı yönlerine karşılık gelecek şekilde başlangıç konumu ve hedef arasında yakınsamayı sağlamak üzere gerçekleştirilir.

Her bir ayrık zaman diliminde verilen yeni karar, arayüz tarafından algılanır ve obje; zihinsel görev üzerinden tanımlanmış belirli bir yönde hareket eder. Hiyerarşik kontrol stratejisine ait protokol Şekil 2.29'da gösterilmiştir [35].

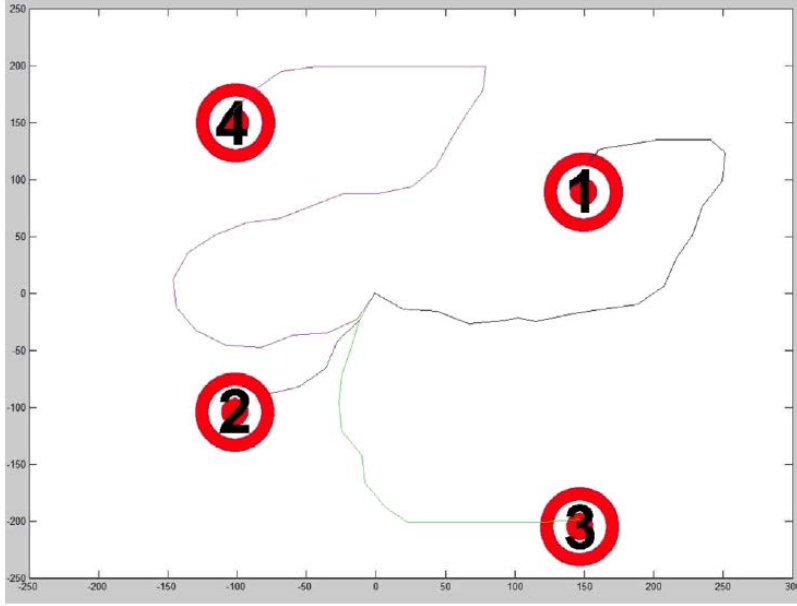


Şekil 2.29: Hiyerarşik strateji protokolü

2.8.3. Yönel kontrol stratejisi

İkinci kontrol stratejisi de, kullanıcının, hareketin yönünü sürekli modda kontrol etmesini sağlar. Bu kontrol stratejisi ile, hedefe daha hızlı bir şekilde ulaşma gerçekleştirilir. Bu arayüzde; kullanıcı, zihinsel görevler icra ederek oku hareket ettirir. Okun ucu, objenin hareketinin yönünü tayin eder. Kullanıcı, oku sağ ya da sola doğru hareket ettirir ve ok; her bir zihinsel görev gerçekleştiğinde, belirli bir açı miktarı kadar sapar. Belirli bir zaman aralığında, obje okun gösterdiği yönde hareket eder ve çevrelediği tekerlek de, yeni limitleri göstermek üzere güncellenir. Her yeni kontrol komutu ile, objenin seçilen yönde belirli bir mesafe kat etmesi sağlanır. Hiyerarşik kontrol ile kıyaslandığında, bu stratejinin dezavantajı, görece daha düşük hassasiyete ve doğruluğa sahip olmasıdır.

Şekil 2.30'da, gerçek-zamanda yönel kontrol stratejisini uygulayarak belirli hedeflere ulaşılması işlemini gerçekleştiren BCI gösterilmektedir.



Şekil 2.30: Yönsel strateji kullanılarak hedeflere erişilmesi [35]

Bu metotlar, motor engellilikleri olan kişilerde denenip, kullanılabilirliği kıyaslanabilir.

2.8.4. Model değerlendirme metotları

2.8.4.1.Kappa değeri

Sınıflama ölçeği düzeyindeki kategorik veriler için kullanılan bir ilişki ölçüsüdür. Cohen tarafından geliştirilmiş bir istatistiktir. Kategorik değişkenlerin, değerleyici uzlaşımını ölçmek ve nicel olarak göstermek için kullanılır. Kappa katsayısı, N tane birimi, C tane ayrı kategori altında sınıflandıran iki değerleyici arasındaki uzlaşma seviyesini ölçümler. Burada, değerleyici; cevaplayıcı olarak, uzlaşma ise; orijinal ve tekrar görüşme arasındaki tutarlılık olarak değerlendirilir. Hesaplanan Kappa katsayısı, orijinal görüşme ile, yeniden görüşme verileri arasındaki uyumu ifade etmektedir. Tablo 2.2'de Kappa değerinin hesaplanmasına ilişkin verilen, değerleyici tablosu gösterilmiştir.

Tablo 2.2:Değerleyici tablosu

I.Değerleyici	II.Değerleyici		Toplam
	1	2	
1	P_{11}	P_{12}	$P_{1.}$
2	P_{21}	P_{22}	$P_{2.}$
Toplam	$P_{.1}$	$P_{.2}$	1

Kappa katsayısının hesaplanabilmesi için, öncelikle uzlaşma seviyesinin belirlenmesi gereklidir. Uzlaşma seviyesi aşağıdaki gibi hesaplanabilir [68].

$$\Pr(a) = P_{11} + P_{22} \quad (2.104)$$

Bu değer, iki değerlendiricinin tümüyle bağımsız olması varsayılarak elde edilen değerle kıyaslanmalıdır.

$$\Pr(e) = P_{11}P_{1.} + P_{22}P_{2.} \quad (2.105)$$

$\Pr(a)$, değerlendiriciler arasında gözlenen uzlaşma yüzdesi iken, $\Pr(e)$ ise şans uzlaşmasının hipotetik olasılığıdır.

$\Pr(a)$ ve $\Pr(e)$ kullanılarak Kappa katsayısı aşağıdaki gibi tanımlanır

$$K = \frac{\Pr(a) - \Pr(e)}{1 - \Pr(e)} \quad (2.106)$$

Kappa değeri küçüldükçe, değerlendiriciler arasındaki uzlaşma düzeyi de düşer. Kappa değeri, 0-1 arasında değişen bir ölçü olmakla beraber, 1'e yaklaştıkça uyuma oranı artmaktadır [66].

0.93-1 arası mükemmel, 0.81-0.92 arası çok iyi, 0.61-0.8 arası iyi, 0.41-0.6 arası orta düzeyde, 0.21-0.4 arası ortanın altında ve 0.01-0.2 arası zayıf uyumu tanımlamaktadır [67].

Bu metod, aynı nesneyi derecelendiren iki gözlemci arasında gerçekleşen uyumu kontrol etmek amacı ile geliştirilmiştir.

2.8.4.2. Hatanın karesinin ortalamasının karekökü

Hatanın Karesinin Ortalamasının Karekökü (RMSE), genellikle modellenmiş çevre tarafından gözlemlenen güncel değerler ve model tarafından tahmin edilen değerler arasındaki farkın bir ölçütü olarak kullanılır. Bu bireysel farklar, artık olarak tanımlanır. RMSE metodu, bu artık değerlerin, tekil bir tahmin gücü ölçütüne doğru kümeleştirilmesini sağlar.

Kestirilen değişkene X_{model} göre, model tahmininin RMSE'si hatanın karesinin ortalamasının karekökü olarak hesaplanır.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (X_{\text{obs},i} - X_{\text{model},i})^2}{n}} \quad (2.107)$$

Burada, X_{obs} , gözlemlenen değerler, ve X_{model} i . zamana ya da konuma ait modellenmiş değerlerdir. Hesaplanan RMSE değerleri, model performansının kalibrasyon periyodunda fark edilmesinde ve bireysel model performanslarının kıyaslanmasında kullanılır.

2.8.4.3. Normalize edilmiş hatanın karesinin ortalamasının karekökü

RMSE'nin boyutsuz formları, genellikle değişik birimlerin kıyaslanmasında kullanılır. Normalize Edilmiş Hatanın Karesinin Ortalamasının Karekökü (NRMSE) hesaplamasında iki farklı yaklaşım vardır. İlki RMSE değerini, gözlemlenen verilerin aralığına göre normalize etmek iken; diğeri ise, gözlemlenen verilerin ortalamasına göre normalize etmektir.

$$\text{NMRSE} = \frac{\text{RMSE}}{X_{\text{obs,max}} - X_{\text{obs,min}}} \quad (2.108)$$

$$\text{NRMSE} = \frac{\text{RMSE}}{\bar{X}_{\text{obs}}} \quad (2.109)$$

2.8.4.4. Pearson korelasyon katsayısı

Korelasyon, genellikle bir korelasyon katsayısı olarak ölçülmekle birlikte, gözlemlenen değerler ve model çıktıları gibi iki tür değişken arasındaki doğrusal ilişkinin yönünü ve gücünü işaret eder. Farklı durumlar için, farklı türden katsayılar kullanılır. Bunlardan en iyi bilineni de Pearson çarpım-moment korelasyon katsayısıdır.

İki değişkenin kovaryanslarının standart sapmalarının çarpımına bölünmesi ile elde edilir. Eğer n seride gözlem ve n tane model değeri varsa, o zaman Pearson çarpım-moment korelasyon katsayısı, model ve gözlemler arasındaki korelasyonun kestirilmesi için kullanılabilir.

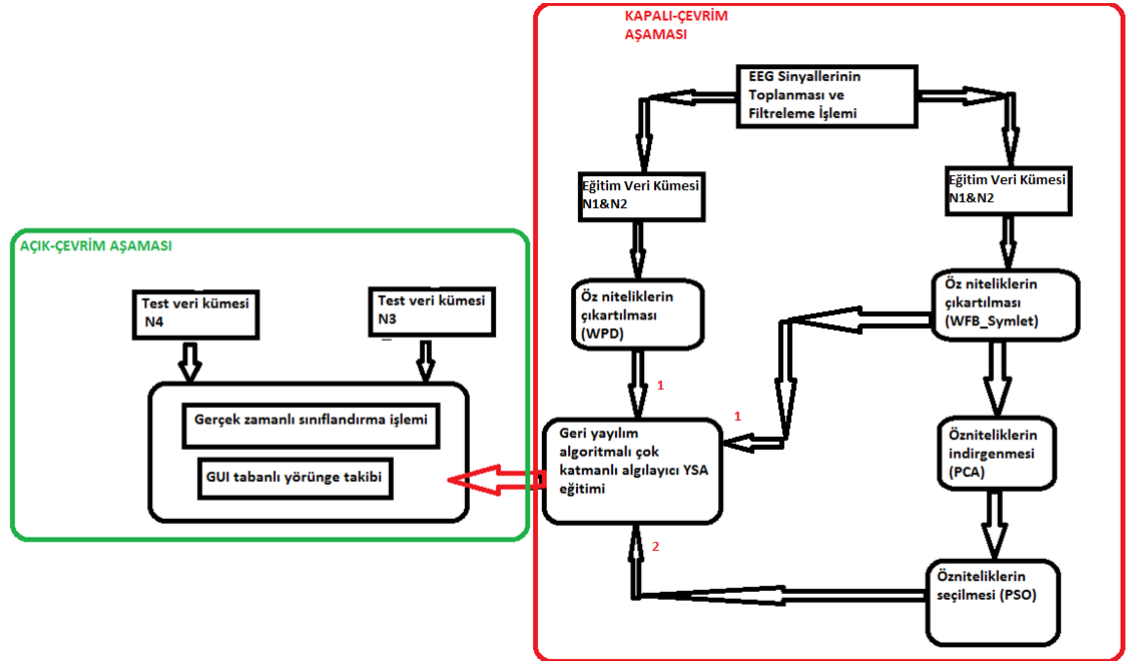
$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.110)$$

Mükemmel artan doğrusal ilişkinin olması durumunda korelasyon +1 değerini alırken, azalan doğrusal ilişkinin olması durumunda -1 değerini alır. Korelasyon katsayısının sıfır değerinin alması durumunda ise, değişkenler arasında doğrusal bir ilişkinin olmadığı sonucuna varılır. Pearson korelasyon katsayısının karesi (r^2), iki değişken arasında ne kadarlık bir varyans olduğunu tanımlar.

3.GEREÇ VE YÖNTEM

Çoklu-görev sınıflandırması için seçilecek olan öznelikler ile, bu özneliklere ilişkin metotlar, ilk aşamada kapalı-çevrim halinde yüksek performans kriterlerine göre belirlenmiştir. Sınıflandırıcıya ait eğitim işlemi, bu aşamada gerçekleştirilmiş ve gerekli öznelik vektörleri elde edilmiştir. İkinci aşamada ise, yeni test verileri ile, açık-çevrimde sınıflandırma işlemi yapılmıştır.

Kapalı-çevrim ve açık-çevrim sınıflandırmasına ait uygulanan zihinsel görevler sırasıyla; “alfabeyi tersten sayma”, “küp döndürme imajinasyonu/sağ elin hareket ettirilmesi”, “sol kolun hareket ettirilmesi”, “matematiksel işlemlerin yapılması” şeklindedir. PCA, öznelik kümelerindeki fazlalıktan kaçınmak ve gerçek-zamanlı sınıflandırma performansını arttırmak için kullanılmıştır. Deneysel çalışmada ise, BCI kullanılarak, hiyerarşik yörünge kontrolü gerçekleştirilmiştir ve sistemin performansı deneysel olarak test edilmiştir. BCI tasarımına ait önerilen stratejinin akış şeması Şekil 3.1’de gösterilmiştir.



Şekil 3.1: BCI’da, yörünge takibi için önerilen sistem metodolojisi/akış şeması


3.1. DeneySEL Kurulum ve Verilerin Toplanması Aşaması

Bu tezde, EEG sinyal işleme yöntemi kullanılarak, BCI aracılığı ile, gerçek-zamanlı yürünge takibinin yapılması hedeflenmektedir. Test objesini; sağ, sol, yukarı, aşağı yönlerde hareket ettirebilmek için, 4 farklı zihinsel görev ataması ve haritalandırılması yapılmıştır.

Emotiv şirketi tarafından üretilen EPOC kulaklığı, verilerin gerçek-zamanlı olarak toplanması için kullanılmıştır. Başlık, beynin her iki yarımküresinde yedişer adet olmak üzere, toplam 14 kanal içermektedir. Zihinsel görevlerin icra edilmesi sırasında,

Şekil 3.2’de gösterilen, 14 sensör kanalından (AF3 – F7 – F3 – FC5 – T7 – P7 – O1 – O2 – P8 – T8 – O1 – O2 – P8 – T8 – FC6 – F4 – F8 – AF4) veriler alınmıştır. Bu elektrotlar, 5-100 μV ’luk beyin aktivitesi tarafından üretilen elektiksel potansiyellerini ölçer. Simulink bloğu, EEG dadasını bir vektör formatında almakta ve sonraki sinyal işleme aşamaları için Simulink ortamında tutmaktadır. Örnekleme frekansı 128 Hz.’dir.

Kaydedilen bu veriler, Matlab ortamına aktarılıp, sırasıyla; filtreleme, öznitelik çıkartma, öznitelik indirgeme, öznitelik seçme, sınıflandırma ve kontrol sinyaline kodlama işlemlerinden geçirilerek, BCI’de, gerçek-zamanda yürünge takibi işleminin yapılması için kullanılacaktır.



Şekil 3.2: Emotiv EPOC standart kulaklığı


Veriler bilgisayar ortamına kaydedilirken; "Matlab&Simulink" ile etkileşen bir BCI olan "Simulink EEG Importer" programı kullanılmıştır. Bu sayede, Emotiv EPOC kulaklığından gelen gerçek-zamanlı EEG verileri "Matlab&Simulink" modeline aktarılabilmektedir. Şekil 3.3'te, "EPOC-Simulink Sinyal Server"'na ait Grafiksel Kullanıcı Arayüzü (GUI) gösterilmektedir.




Şekil 3.3: EPOC-Simulink Sinyal Server GUI

Şekil 3.4'te, Emotiv EPOC EEG'ye ait Simulink modeli ve skop üzerinden okunan gerçek-zamanlı ham EEG sinyali görülmektedir.

(a)




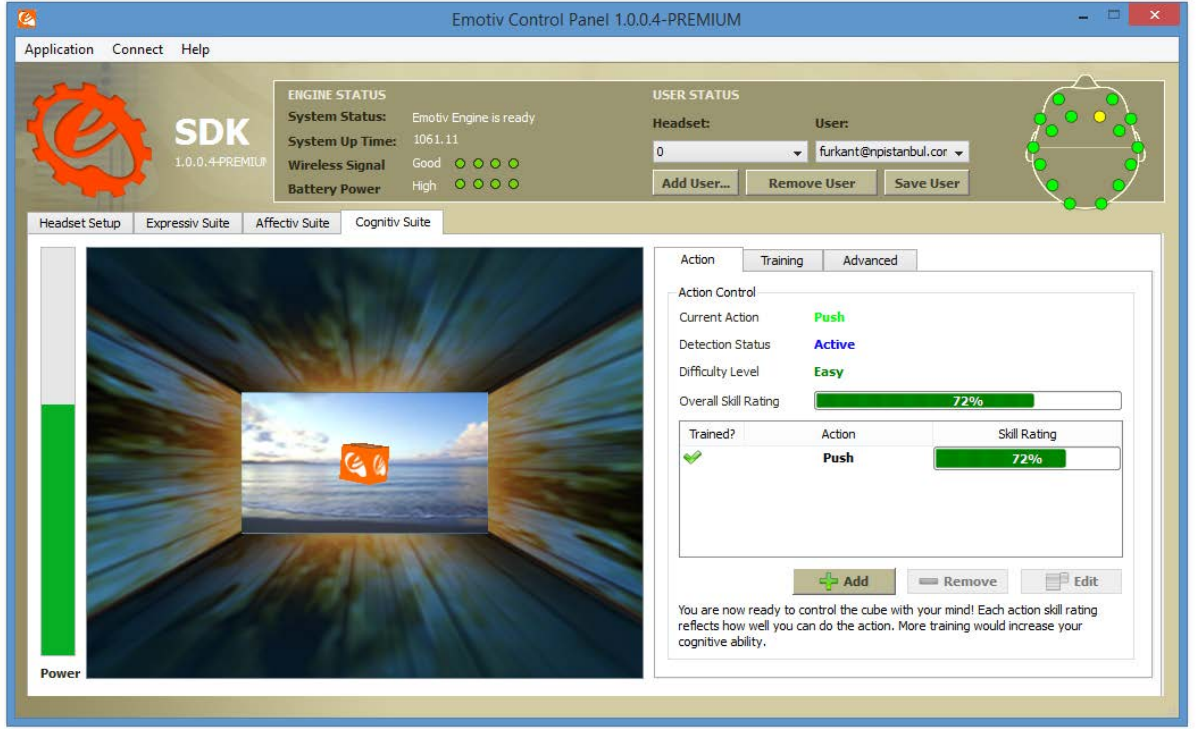
(b)



Şekil 3.4: Emotiv EPOC Simulink Modeli a)ham EEG datasını gösteren Simulink Modeli
b)Gerçek-zamanlı ham EEG datasını gösteren scope


Şekil 3.5'te ise, Emotiv programına ait test arayüzünden ve kontrol panelinden bir kesit sunulmaktadır.





Şekil 3.5: Emotiv programına ait test ortamı ve kontrol paneli

Her bir kanala ait hesaplanan FFT spektrumları da, Emotiv yazılım paketinde Şekil 3.6'daki gibi gösterilmektedir.



Şekil 3.6: Her bir elektrot kanalına ait FFT spektrumlarının gösterilmesi

3.2. Ön İşleme ve Özniteliklerin Çıkartılması Aşaması

Ham data, artefakların ve gürültülerin ortadan kaldırılabilmesi için, öncelikle 50 Hz.'lik "bant durdurucu" filtreden, sonra da 0.5-45 Hz.'lik kesim frekanslarına sahip 6.dereceden "Butterworth bant-geçiren" filtreden geçirilerek filtrelenmiştir.

Zihinsel görevler gerçekleştirilirken,her bir zihinsel görev için, 0-30 saniye aralığında 40 epok eğitim datası ve 10 epok test datası toplanmıştır. Bu zihinsel görevler sırasıyla; "alfabeyi tersten sayma", "küp döndürme imajinasyonu/sağ el hareketi", "sol kol hareketi", "matematiksels işlem" şeklindedir.

Eğitim ve test veri kümesi N1-N3; "alfabeyi tersten sayma", "küp döndürme imajinasyonu", "sol kol hareketi", "matematiksels işlem" zihinsel görevlerini içerirken, N2-N4 ise; "alfabeyi tersten sayma", "sağ el hareketi", "sol kol hareketi", "matematiksels işlem" zihinsel görevlerini içermektedir.

Daha sonra bu veriler, 1'er saniyelik parçalara bölünerek toplamda $14(\text{sensörkanalı}) \times [4(\text{görev}) * 40(\text{epok}) * 31(\text{saniye})]$ eğitim veri matrisi ve $14(\text{sensörkanalı}) \times [4(\text{görev}) * 10(\text{epok}) * 31(\text{saniye})]$ test veri matrisi elde edilmiştir.

Tüm veriler, 1 saniyeye bölünmüş ve 128 Hz.'de örneklenmiştir. Bu yüzden, tek bir saniyelik segment üzerinde 128 tane öznitelik verisi tutulmaktadır.

Özniteliklerin çıkartılması için uygulanması gereken metotların seçimi oldukça önemlidir. EEG durağan olmayan sinyal olduğu için, FFT ve STFT dönüşümlerini kullanmak, sinyalin durağan kaldığı pencerelerin seçimi açısından sınırlıdır.

Oysa,WT; yüksek frekanslı sinyal için küçük pencere ve düşük frekanslı sinyal için geniş pencere şeklinde değişen pencere boyutları ile, matematiksels bir mikroskop gibi davranır. Sınırlı enerjiye sahip durağan olmayan sinyaller, ana dalgacık fonksiyonunun $\psi(t)$ genişlemesi ve ilerlemesi şeklinde ifade edilirler. Birçok ortogonal dalgacık çeşidi vardır. Bunlardan bazıları, "Haar-Meyer" ve "Shannon-Daubechies"dir.

Kapalı-çevrim sınıflandırılması için kullanılacak öznitelikler çıkartılırken, eğitim veri kümelerine (N1&N2) çoklu sinyal WPD metodu ve symlet ana dalgacığını içeren WFB metodu uygulanmıştır.

Eđitim verilerine bađlı olarak eđitilen ANN sınıflandırıcısı üzerinde, test veri kümeleri (N3) ve (N4), test edilmiş ve en yüksek açık-çevrim sınıflandırma doğruluđu gösteren yöntem seçilerek, onun üzerinde, PCA ile özniteliklerin indirgenmesi ve PSO ile FS işlemleri yapılmıştır.

Elde edilen optimal öznitelik vektörleri, gerçek-zamanlı BCI'nın yörünge takip kontrolü için kullanılmıştır. Sınıflandırma algoritmasının girişleri, bu verilerin, ileride anlatılacak olan spesifik öznitelik çıkartma metotlarının uygulanması sonucu oluşturulmuş her bir göreve ait elektrot kanallarından çıkartılan öznitelik vektörlerinin birleştirilmesiyle elde edilir. Her bir öznitelik için; eğitim datası girişleri matrisinin boyutları 14x4960, test datası girişleri matrisinin boyutları ise 14x1240'tır.

3.3.Uygulanan Öznitelik Çıkartma Metotlarının İncelenmesi

3.3.1.Symlet ana dalgacığı tabanlı WFB

Dalgacık terimi; f_0 temel frekansı ile osilasyon halinde sonlu genişliğe sahip bir pencere fonksiyonunu ifade eder. Dalgacık penceresi, ana-dalgacık olarak adlandırılır. Bu teknik ile, EEG sinyalinin ilişkili parametreler çıkartılır.

STFT, sabit boyutlu pencere kullanır ve Heisenberg eşitsizliği ile sınırlı bir zaman-frekans çözünürlüğüne sahiptir.

$$\Delta f * \Delta t \geq \frac{1}{4\pi} \quad (3.1)$$

Zaman domeninde çözünürlük arttığında, frekans domeninde çözünürlük azalır veya tam tersi biçimde; frekans domeninde çözünürlük artarsa, zaman domeninde azalır.

STFT'nin ikinci temel dezavantajı ise, pencere kalınlığı zaman içinde sabittir ve bu da durađan olmayan bir sinyali analiz ederken, istenmeyen bir özelliktir.

CWT aşağıdaki formül ile gösterilir [20].

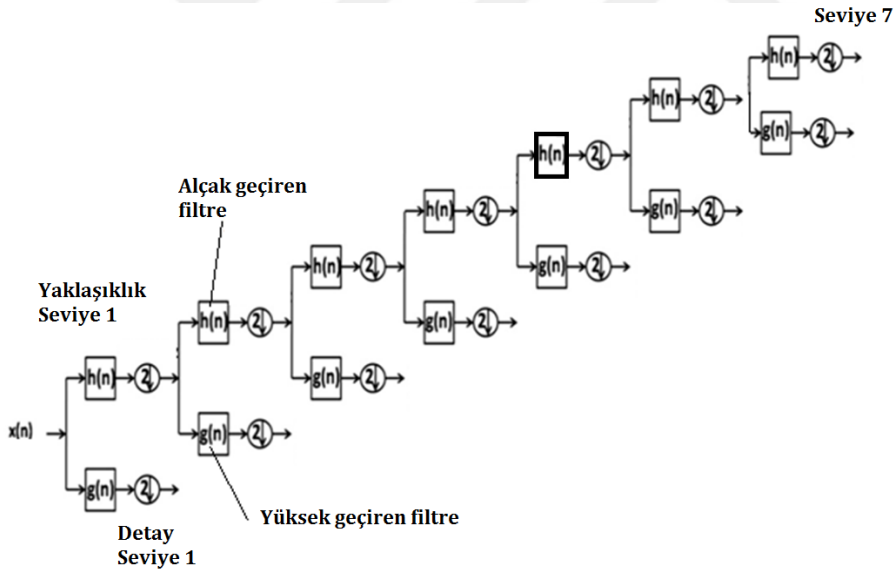
$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t)\psi(t)\left\{\frac{t-b}{a}\right\} dt \quad (3.2)$$

$\psi(t)$ ana dalgacık fonksiyonu, deneme-yanılma yolu ile seçilir. $\frac{1}{\sqrt{a}}$ faktörü sinyalin enerjisini normalize etmek için kullanılır. Ana dalgacık fonksiyonu, EEG sinyalinin bölümlerinin analiz edilmesi için zaman içinde kaydırılır.

Ölçek faktörü, $a = \frac{1}{f}$, frekansın tersidir. a 'nın küçük değerleri için, dalgacık, orijinal sinyalin dar fonksiyonudur ve yüksek frekanslara karşılık gelir. a 'nın büyük değerleri için ise, dalgacık genişler ve düşük frekanslara karşılık gelir. b ise dönüşüm değişkenidir ve pencere sinyal boyunca kaydırılırken pencerenin merkezindeki konuma denk gelir. $a \neq 0$ ise ve dalgacık, $a = 2^m$ gibi bir ikili operasyon ile genişletilip, $b = k.2^m$ dönüşüm değişkeni ile de dönüştürülürse, DWT yapılmış olur. Her ortogonal dalgacık için bir analiz ve sentez filtre bankası vardır. Bu filtre bankası kullanılarak sinyal analiz edilir ve alt örnekleme operasyonu ile dalgacık katsayıları üretilir.

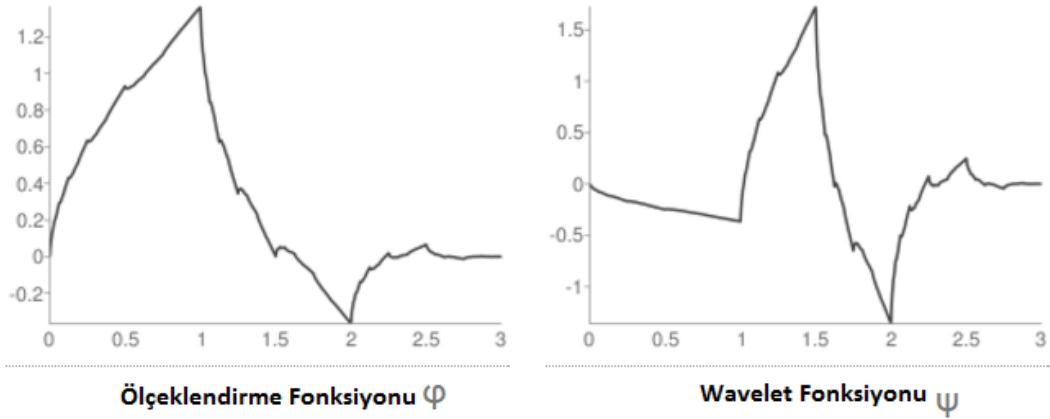
Sinyal ayrıştırmasının anlamı, dalgacıkları bant geçiren filtreler olarak yorumlamaktır. Filtre bankası her dekompozisyon seviyesi için bir alçak geçiren bir de yüksek geçiren filtreden meydana gelir.

Şekil 3.7'de, tezde kullanılan 7. seviyede ayrıştırma yapabilen WFB gösterilmiştir.



Şekil 3.7: 7. Seviyedeki WFB


Şekil 3.8'de Symlet-2'ye ait ölçeklendirme ve ana dalgacık fonksiyonu gösterilmektedir.



Şekil 3.8: Symlet-2 dalgacığa ait ölçeklendirme ve ana dalgacık fonksiyonu


CWT, hesaplama açısından verimsizdir ve ANN sınıflandırma işlemi için uygun olmayan gereksiz bilgiler üretir. Bu yüzden DWT bant altı kodlama yöntemi kullanılmıştır.

Bu teknik, sinyali belirli frekans bölümlerine ayırdığından ve aynı zamanda EEG sinyalinin doğal frekans bandları (alfa-beta-delta-teta ritimleri) ile benzerlik gösterdiğinden dolayı avantajlıdır. Multi-rate filtre bankası, yarım bant yüksek geçiren ve alçak geçiren doğrusal fazlı FIR filtre serilerini içerir. Şekil 3.9'da bu yöntem gösterilmiştir [21,22].



Şekil 3.9: Bant altı kodlama yöntemi s(1):BETA β ; s(2):ALFA α ; s(3):TETA θ ; s(4): DELTA δ

Bu işlem sonucunda 7.seviyeye kadar çıkartılan dalgacık katsayıları zaman formatında Şekil 3.10'da gösterilmiştir.



Şekil 3.10: Zaman formatında ifade edilen dalgacık dönüşümü katsayıları

Her seviye, zaman domeninde birleştirilmiş ve zaman-şiddet eksenlerinde gösterilmiştir. DWT, EEG sinyallerine uygulandığında, her bant altı için bir frekans spektrumu üretilir. Veri setine ait örnekleme frekansı 128 Hz.'dir. EEG sinyaline ait maksimum frekans da 64 Hz. olmaktadır. 1.seviyedeki ayrıştırma için, detay bileşeni 64-32 Hz.'lik frekans bandında iken, yaklaşıklık bileşenine ait frekans bandı 0-32 Hz. arasındadır. İkinci seviyede ise, detay ve yaklaşıklık bileşenlerine ait frekans bantları sırasıyla, 32-16 Hz. ve 0-16 Hz. olmaktadır. Ayrıştırılan seviyelerin frekans aralıkları Tablo 3.1'de verilmiştir.

Tablo 3.1: Ayrıştırılan seviyelere ait frekans aralıkları

Seviye	Detay	Yaklaşıklık
1	32--64	0--32
2	16--32	0--16
3	8--16	0--8
4	4--8	0--4
5	2--4	0--2
6	1--2	0--1
7	0.5--1	0--0.5

3.3.2. Dalgacık paketi dekompozisyonu

Biyomedikal sinyallerin, genellikle kısa yüksek frekanslı bileşenleri büyük ölçüde zaman domeninde sıkışırken, buna eşlik eden düşük frekanslı bileşenleri de frekans domeninde konumlanmıştır. WT, bu şekildeki durağan olmayan sinyalleri analiz etmek için, düşük frekanslı bileşenleri geniş zaman spektrumunda, yüksek frekanslı bileşenleri de dar zaman spektrumunda çözümler. Zaman-frekans çoklu çözünürlük yaklaşımları WPD yöntemi ile genelleştirilmiştir. WPD, sinyalin kolay analizini sağlayan soy ağaçlarına ayırdığından bant altı kodlama şemalarından daha esnek bir analiz imkanı sağlamaktadır [23].

Sinyal, alt uzayların ağaçları şeklinde modellenir. $\Omega_{0,0}$, orijinal sinyal uzayını, ağacın kök düğümünü gösterir. Genel notasyonda, $\Omega_{j,k}$ düğümünü ele alırsak; j , skalayı ve k , skalaya bağlı bant altı indeksini gösterir. Bu düğüm, $\Omega_{j,k} \rightarrow \Omega_{j+1,2k}$ yakınsama uzayı ve buna ek olarak $\Omega_{j,k} \rightarrow \Omega_{j+1,2k+1}$ detay uzayı şeklinde iki ortogonal, birbirine dik alt uzaya ayrıştırılır.

Bu işlem $\Omega_{j,k}$ 'nin ortogonal temelini $\{\phi_j(t - 2^j k)\}_{k \in \mathbb{Z}}$; $\Omega_{j+1,2k}$ 'nin $\{\phi_{j+1}(t - 2^{j+1} k)\}_{k \in \mathbb{Z}}$ ve $\Omega_{j+1,2k+1}$ 'in $\{\psi_{j+1}(t - 2^{j+1} k)\}_{k \in \mathbb{Z}}$ yeni ortogonal temellerine bölerek yapılır. Burada $\phi_{j,k}(t)$ ve $\psi_{j,k}(t)$ ölçekleme ve dalgacık fonksiyonlarıdır.

$$\phi_{j,k}(t) = \frac{1}{\sqrt{|2^j|}} \phi\left(\frac{t-2^j k}{2^j}\right) \quad (3.3)$$

$$\psi_{j,k}(t) = \frac{1}{\sqrt{|2^j|}} \psi\left(\frac{t-2^j k}{2^j}\right) \quad (3.4)$$

2^j : gecikme faktörü, ölçekleme parametresi

$2^j k$: öteleme parametresi, dalgacığın zaman lokasyonunu belirler


Bu işlemin WT'den farkı, WPT yönteminin, sinyali yaklaşım ve detay katsayıları olarak ayrıştırmasıdır. Bu işlem J kere tekrar edilir, burada J 'nin değeri;

$J \leq \log_2 N$ eşitsizliğine göre belirlenir. N ; orijinal sinyalin örnekleme değeridir.

$J \times N$ 'lik bir katsayı matrisi üretilmiş olur [24].

Çözünürlük seviyesi j 'de $\{j = 1, 2, \dots, J\}$, N adet katsayı içerir ve 2^j adet katsayı bloğuna ayrıştırılır. Bu iteratif işlem, ikili dalgacık paketi ağaç yapısını oluşturur. Ağaç düğümleri farklı frekanslarda lokalize olan alt uzay karakteristiklerini gösterir.

Şekil 3.11'de WPD'ye ait soy ağacı yapısı gösterilmektedir.




Şekil 3.11: WPD soy ağacı yapısının şematik gösterimi

Bu dönüşüm yöntemi, her seviyede ikili ağaç şeklini vererek sinyali çözümler. Uygun filtre yardımı ile, soy ağacının herhangi bir parçası sinyalin ortonormal dekompozisyonu sonucunu verecek şekilde seçilebilir.

Alt bant kodlamada ağacın sadece alçak geçiren filtre çıkışları, yüksek ve alçak çıktılara bölünür. Ancak WPT kullanılarak oluşturulan ikili ağaç yapısında en uygun ortonormal temel seçilebilir. Bu seçim işlemi, maliyet fonksiyonunun minimizasyonu prosesi temelindeki arama algoritmalarına bağlıdır [25].

“Budama Algoritması” ve “Büyüme Algoritması”, şeklinde iki farklı arama algoritması vardır. Budama algoritması ilk önce tam ikili ağacı genişletir ve aramayı dallardan köklere doğru gerçekleştirir. Büyüme algoritması da, ağacı genişletmeye köklerden başlar ve minimizasyon şartları başarıldığı zaman durur. Sinyal, ilk önce kafeslere ayrılır ve en iyi temel arama, farklı algoritma ve maliyet fonksiyonları kullanılarak yürütülür. Maliyet fonksiyonları sinyal enerjisinin dağılımını ölçer. Bu fonksiyonlar "Shannon", "log-enerji", "coifman-wickerhauser" entropi türlerini kapsar.

Şekil 3.12'de, Dalgacık Paketi Dönüşümü (WPT), ağaç yapısı ve zaman-frekans düzlemindeki dağılımı gösterilmiştir.



Şekil 3.12: WPT ağaç yapısı ve zaman-frekans düzleminde gösterilişi

WPD kodu, Matlab ortamında yazılmıştır. Her bir sensör kanalından gelen [3841x1] boyutlarındaki sinyallerin öznitelikleri aşağıdaki koda göre hesaplanmıştır.

winsize=128;

wininc=16;

J=7;

Features = getmswpfeat(x,winsize,wininc,J,'matlab');

Her bir pencere içerisinde 128 tane örnek barındırır. Pencere artım miktarı 16 olarak belirlenmiştir ve 7.seviyeye kadar ayrıştırma yapılmıştır. 7.seviyedeki tam soy ağacı için toplamda, $255(2^N - 1, N = 7)$ adet düğüm çıkartılır.

Seviye 0= 1 düğüm

Seviye 1= 2 düğüm

Seviye 2=4 düğüm

Seviye 3=8 düğüm

Seviye 4=16 düğüm

Seviye 5=32 düğüm

Seviye 6=64 düğüm

Seviye 7=128 düğüm

Ana dalgacık fonksiyonu olarak, "Daubechies-4" seçilmiştir. Budama arama algoritması ve "log-enerji" maliyet fonksiyonu kullanılmıştır. Bu işlem sonucunda her bir düğüm 233 tane eleman barındıran katsayı vektörü içerir. Her bir elektrot kanalı için toplamda, 233x255'lik bir katsayı vektör uzayı oluşur.

Ancak bu katsayılar tek başına sınıflandırma için yeterli değildir. Her bir düğümdeki bu katsayılar üzerinde aşağıdaki formülasyonu uygulayarak, bir öznitelik vektörü kümelenmesinin oluşturulması gereklidir. Formülasyon, Matlab komutları şeklinde aşağıdaki gibi verilmiştir.

$$\gamma_{i,j} = \text{sqr}(\text{abs}(\text{sum}(\text{diff}(\text{fft}(\Omega_{i,j})))))) \quad (3.5)$$


Burada;

$\Omega_{i,j}$:düğüm vektörü

$\gamma_{i,j}$: düğüme ait öznelik

(5,2),(5,3),(5,4),(5,5),(5,6),(5,7),(6,2),(6,3),(6,4),(6,5),(6,6),(6,7),(7,2),(7,3),(7,4),(7,5),
(7,6),(7,7) düğümlerindeki 18 öznelik değeri sınıflandırma algoritmasında test edilmek üzere kullanılmıştır ve en yüksek sınıflandırma performansı değerini (7,2) nodu vermiştir.

Şekil 3.13'te WPD'nin Matlab ortamındaki gösterimi verilmiştir.



Şekil 3.13:WPD'nin Matlab ortamındaki gösterimi

3.4.Öznitelik İndirgeme Aşaması

İşe yarar bilginin çıkartılması için, WFB'ye ilişkin detay ve yaklaşıklık seviyesinin belirlenmesi gereklidir. En belirleyici özniteliklerin çıkartılması ve öznitelik vektörünün boyutlarının azaltılması işlemi de PCA ile gerçekleştirilmektedir. Verili X sinyalinin n -boyutlu girdi vektörüne ait $n \times n$ 'lik ortonormal projeksiyonu P aşağıdaki gibidir:

$$Y = P^T X \quad (3.6)$$

Y 'ye ait kovaryans matrisi $\text{cov}(Y)$, X ve P cinsinden aşağıdaki gibi hesaplanır:

$$\begin{aligned} P^{-1} &= P^T \\ \text{cov}(Y) &= E[YY^T] \\ &= E[(P^T X)(P^T X)^T] \\ &= E[(P^T X)(X^T P)] \\ &= P^T E[XX^T]P \\ &= P^T \text{cov}(X)P \end{aligned} \quad (3.7)$$

$$P \text{cov}(Y) = PP^T \text{cov}(X)P = \text{cov}(X)P \quad (3.8)$$

P , burada $d \times 1$ 'lik sütun vektörüne karşılık gelmektedir.

$$P = [P_1, P_2, \dots, P_n]$$

$\text{cov}(Y)$ 'de özdeğerler cinsinden aşağıdaki gibi yazılırsa;

$$\begin{bmatrix} \lambda_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_n \end{bmatrix}$$

$$P \cdot \text{cov}(Y) = [\lambda_1 P_1, \dots, \lambda_n P_n] = [\text{cov}(X)P_1, \dots, \text{cov}(X)P_n] \quad (3.9)$$

$$\lambda_i P_i = \text{cov}(X)P_i \quad (3.10)$$

P_i , X 'in kovaryansının özvektörlerine karşılık gelir. Bu sayede, X sinyalinin kovaryans matrisine ait özvektörlerin hesaplanması sonucunda P matrisi elde edilmiş olur.

3.5.Öznitelik Seçimi Aşaması

PSO algoritması kullanılarak sınıflandırmada etkili olan, elektrot tabanlı optimal özellik seçimi yapılmıştır ve bu sayede sınıflandırma için gerekli ağırlıklar kullanılıp işlem yükü azaltılmış, sınıflandırma performansı artırılmıştır.

3.6.Sınıflandırma Aşaması

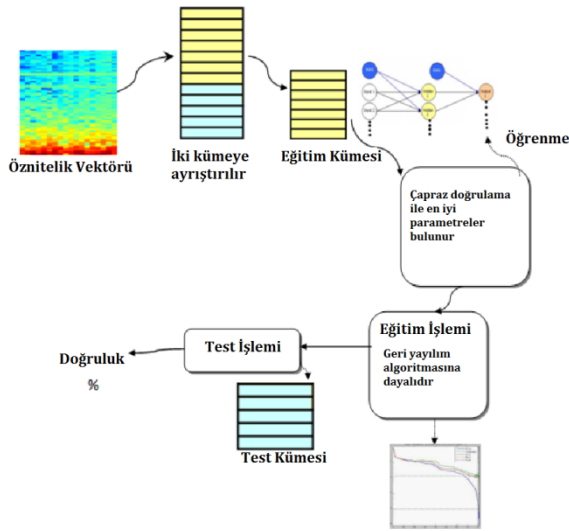
Her zihinsel görev ve buna ilişkin sensör kanallarına ait verilerin öznitelik vektörleri,sınıflandırma yapılması için geri yayılım algoritmasını kullanan MLP ANN'ye girdi olarak verilirler. Geri yayılım algoritmasında, ağırlıklar ve bias'ları ağ hatasının karelerinin toplamını minimize etmek için sürekli değişir.

Gradyan çöküş prosedürü kullanılarak, hata sinyali global minimuma ulaşılacak şekilde minimize edilir. Geri yayılım algoritması lokal minimumda takılabilir, ancak bu sorun, ağırlık momentum ve öğrenme oranlarını değiştirerek giderilebilir. ANN için parametreler; 190 nöronlu 1 gizli katman, 0.03'lük öğrenme oranı ve 0.2'lik momentum oranı, performans kriteri "mse" olarak belirlenmiş, eğitim algoritması, "ölçekli paylaşım gradyanı" olarak seçilmiştir. Hatanın ortalama karesi 0.0001'in altına indiğinde ya da maksimum iterasyon limiti 10000'e ulaşıldığında eğitim işlemi durmaktadır.

Hata güncel yapay sinir ağı çıktılarının, istenilen hedef çıktıları ile arasındaki fark olarak tanımlanmıştır. Hedef çıktıları, her zihinsel görev için 1 olarak belirlenmiştir. Gizli katmandaki her nöron için "sigmoid" aktivasyon fonksiyonu ve çıktı katmanı için "doğrusal" aktivasyon fonksiyonu uygulanmıştır.


[14x4960]'lık eğitim seti örneğinin %60'ı eğitim, %20'si doğrulama ve %20'si de test için kullanılmıştır. Bu sınıflandırma sonucunda, BCI yürüme takibi kontrolü için giriş sinyalleri elde edilmiştir. Yürüme takibi kontrol stratejisi, "sağ-sol-yukarı-aşağı" yönlerde hiyerarşik olarak yapılmıştır. Deneysel testler verilen referans yürüngenin takibini sağlayacak şekilde tasarlanmıştır. Yürüme takip hatası ve testlerin doğruluk performansları, açık-çevrimde gerçek-zamanlı olarak hesaplanmıştır. Optimal kontrol stratejisi seçimindeki ana kriterler, sınıflandırma doğruluğu ve NRMSE değeridir. Bu sınıflandırma sonucunda, BCI yürüme takibi kontrolü için giriş sinyalleri elde edilmiştir.

Şekil 3.14'te sınıflandırma işlemine ait akış şeması gösterilmektedir.



Şekil 3.14: Sınıflandırma işlemi akış şeması


Şekil 3.15'te ANN'nin mimarisi gösterilmektedir.




Şekil 3.15: ANN mimarisi

Şekil 3.16'da "NN Pattern Recognition" Toolbox'una eğitim verilerinin yüklenmesi işlemi ve ANN'nin eğitim aşaması gösterilmektedir.

(a)

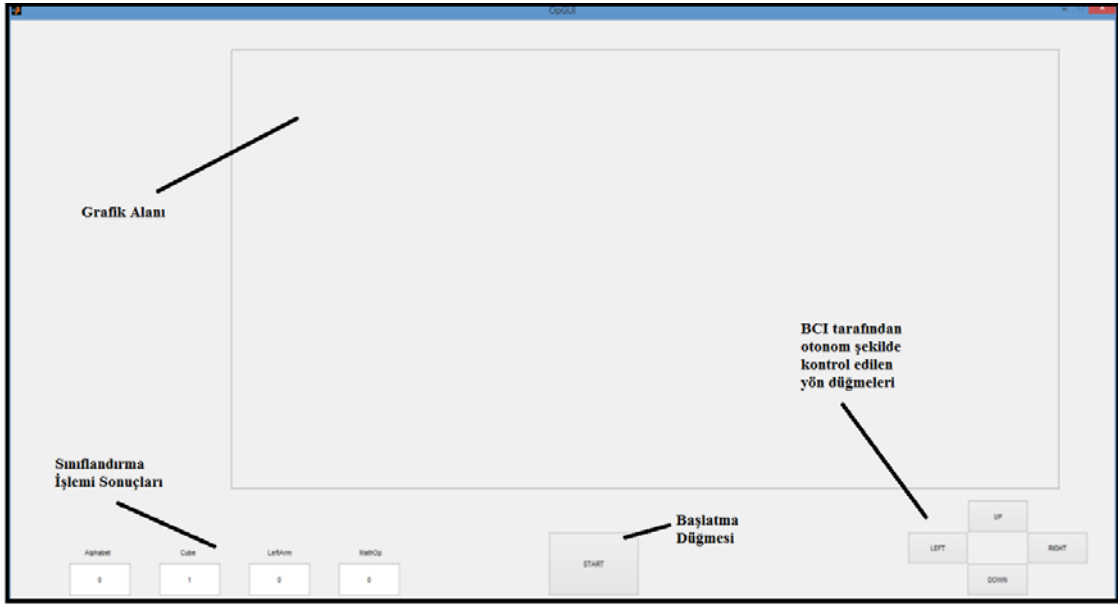


(b)



Şekil 3.16: a) NN Pattern Recognition Toolbox'una eğitim verilerinin yüklenmesi b) ANN eğitim aşaması

3.7.Hiyerarşik Kontrol



Şekil 3.17: Matlab GUI'de tasarlanan BCI

Şekil 3.17'de Matlab GUI'de tasarlanan BCI gösterilmektedir. BCI'ye ait referans yörünge ile güncel yörünge gerçekte-zamanda çizdirilmesini de içeren Matlab GUI kodu Ek 1'de verilmiştir.

Yörünge takibi kontrol stratejisi, "sağ-sol-yukarı-aşağı" yönlerde hiyerarşik olarak yapılmıştır. Deneysel testler verilen referans yörünge takibini sağlayacak şekilde tasarlanmıştır. Yörünge takip hatası ve testlerin doğruluk performansları, açık-çevrimde gerçek-zamanlı olarak hesaplanmıştır. Optimal kontrol stratejisi seçimindeki ana kriterler, sınıflandırma doğruluğu ve NRMSE değeridir.

4. BULGULAR

"N1&N3", eğitim ve test veri kümelerine ilişkin sınıflar: $\{A, C, LA, M\}$ *

"N2&N4", eğitim ve test veri kümelerine ilişkin sınıflar: $\{A, RH, LA, M\}$ *

* A=Alfabeyi tersten sayma, C=Küp döndürme imajinasyonu, RH= Sağ elin hareket ettirilmesi, LA= Sol kolun hareket ettirilmesi, M=Matematik işleminin yapılması

N1, N3 eğitim ve test veri kümeleri sırasıyla, alfabeyi tersten sayma, küp döndürme imajinasyonu, sol kol hareketi ve matematiksel işlem zihinsel görevlere ait sınıfları içerirken, N2, N4 eğitim ve test veri kümeleri de farklı olarak küp döndürme yerine sağ elin hareketine ait zihinsel görev sınıfını içermektedir.

Öncelikle N1 ve N2 eğitim veri kümelerine ait öznelik vektörleri hem WFB hem de WPD metotları ile çıkartılmıştır. Daha sonra ANN, kapalı-çevrimde eğitilmiştir.

Ardından N3 ve N4 test veri kümelerine ait, bu yöntemlere ilişkin öznelik vektörleri ile ANN sınıflandırıcısının açık-çevrim testleri yapılmıştır.

Tablo 4.1 ve 4.2'de kapalı-çevrim ve açık-çevrim simülasyon sonuçları her bir sınıfın birbirleri ile olan kombinasyonları şeklinde gösterilmektedir.

Tablo 4.1:Kapalı-çevrim simülasyon sonuçlarının karşılaştırılması

METOT	WPD	WFB
SINIF		
Alfabe (1) -Küp (2)	%85	%77.3
Alfabe (1) -SağEl (2*)	%88.1	%80.4
Alfabe (1) –SolKol(3)	%92.5	%98.4
Alfabe(1) - Matematik (4)	%93.2	%96.7
Küp(2) –SolKol (3)	%94.8	%98.3
SağEl(2*)-SolKol(3)	%81.2	%96.1
Küp (2) -Matematik (4)	%94.9	%97,6
SağEl (2*) -Matematik (4)	%84.2	%98
SolKol (3) – Matematik (4)	%85.8	%94.4
Alfabe (1) - Küp (2) – SolKol (3)	%84.8	%91.2
Alfabe (1) - SağEl(2*) – SolKol (3)	%80.6	%82.6
Alfabe (1) - Küp (2) – Matematik (4)	%80.4	%88.9
Alfabe (1) - SağEl (2*) – Matematik (4)	%73	%79.3
Alfabe (1) –SolKol(3) – Matematik (4)	%72.8	%83.8
Küp (2) – SolKol (3) – Matematik (4)	%81	%89
SağEl (2*) – SolKol (3) – Matematik (4)	%88.3	%86.3
Alfabe (1) – Küp (2) -SolKol(3)-Matematik(4)	%77.3	%89.6
Alfabe (1) – SağEl (2*) –SolKol (3)-Matematik (4)	%77.7	%80.2

Tablo 4.2: Açık-çevrim simülasyon sonuçlarının karşılaştırılması

METOT	WPD	WFB
SINIF		
Alfabe (1) -Küp (2)	%65.5	%68.4
Alfabe (1) -SağEl (2*)	%64.4	%67.7
Alfabe (1) –SolKol(3)	%88.7	%87.1
Alfabe(1) - Matematik (4)	%92.3	%85.6
Küp(2) –SolKol (3)	%93.2	%87
SağEl(2*)-SolKol(3)	%67.4	%87.1
Küp (2) -Matematik(4)	%92.9	%93.2
SağEl (2*) -Matematik(4)	%85.2	%92.6
SolKol (3) – Matematik (4)	%66.3	%83.6
Alfabe (1) - Küp (2) – SolKol (3)	%82.8	%84.7
Alfabe (1) - SağEl(2*) – SolKol (3)	%84.1	%84.3
Alfabe (1) - Küp (2) – Matematik (4)	%71.7	%83.7
Alfabe (1) - SağEl (2*) – Matematik (4)	%81	%81.6
Alfabe (1) – SolKol (3) – Matematik (4)	%60.4	%82.7
Küp (2) – SolKol (3) – Matematik (4)	%68.5	%82.3
SağEl (2*) – SolKol (3) – Matematik (4)	%86.8	%86.3
Alfabe (1) – Küp (2) -SolKol(3)-Matematik (4)	%70.8	%79.4
Alfabe (1) – SağEl (2*) –SolKol (3)-Matematik (4)	%79.8	%81.5

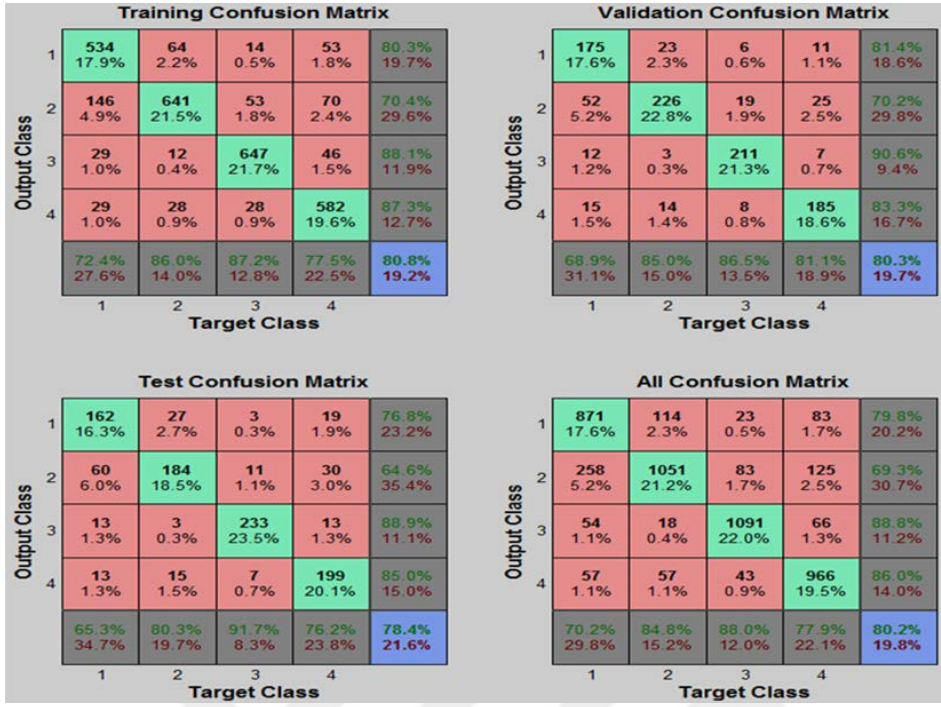
Tablo 4.3'te WFBöznitelik çıkartma metodu kullanılarak elde edilen kapalı-çevrim confusion matrisleri gösterilmiştir.

Tablo 4.3: WFB öznelik çıkarma metodu kullanılarak elde edilen kapalı-çevrim confusion matrisi
a)Alfabeyi tersten sayma, Küp döndürme imajinasyonu, Sol kol hareketi ve Matematik işlemi
zihinsel görevleri için b)Alfabeyi tersten sayma, Sağ el hareketi, Sol kol hareketi ve Matematik
işlemi zihinsel görevleri için

a)



b)



Tablo 4.4.'te WFBöznitelik çıkartma metodu kullanılarak elde edilen açık-çevrim confusion matrisleri gösterilmektedir.

Tablo 4.4: WFB öznitelik çıkartma metodu kullanılarak elde edilen açık-çevrim confusion matrisi
a)Alfabeyi tersten sayma, Küp döndürme imajınasyonu, Sol kol hareketi ve Matematik işlemi zihinsel görevleri için b)Alfabeyi tersten sayma, Sağ el hareketi, Sol kol hareketi ve Matematik işlemi zihinsel görevleri için

a)



b)

Output Class	1	2	3	4	
1	212 17.1%	9 0.7%	8 0.6%	21 1.7%	84.8% 15.2%
2	93 7.5%	284 22.9%	16 1.3%	13 1.0%	70.0% 30.0%
3	3 0.2%	6 0.5%	277 22.3%	38 3.1%	85.5% 14.5%
4	2 0.2%	11 0.9%	9 0.7%	238 19.2%	91.5% 8.5%
	68.4% 31.6%	91.6% 8.4%	89.4% 10.6%	76.8% 23.2%	81.5% 18.5%
Target Class	1	2	3	4	

Tablo 4.5'te WPD öznitelik çıkartma metodu kullanılarak elde edilen kapalı-çevrim confusion matrisleri gösterilmiştir.

Tablo 4.5: WPD öznelik çıkarma metodu kullanılarak elde edilen kapalı-çevrim confusion matrisi
a)Alfabeyi tersten sayma, Küp döndürme imajınasyonu, Sol kol hareketi ve Matematik işlemi zihinsel görevleri için b)Alfabeyi tersten sayma, Sağ el hareketi, Sol kol hareketi ve Matematik işlemi zihinsel görevleri için

a)

		Training Confusion Matrix					Validation Confusion Matrix				
		1	2	3	4	Accuracy	1	2	3	4	Accuracy
Output Class	1	532 17.9%	3 0.1%	59 2.0%	116 3.9%	74.9% 25.1%	180 18.1%	0 0.0%	18 1.8%	34 3.4%	77.6% 22.4%
	2	3 0.1%	660 22.2%	12 0.4%	7 0.2%	96.8% 3.2%	2 0.2%	224 22.6%	2 0.2%	2 0.2%	97.4% 2.6%
	3	106 3.6%	69 2.3%	619 20.8%	148 5.0%	65.7% 34.3%	35 3.5%	23 2.3%	219 22.1%	45 4.5%	68.0% 32.0%
	4	97 3.3%	2 0.1%	67 2.3%	476 16.0%	74.1% 25.9%	23 2.3%	2 0.2%	14 1.4%	169 17.0%	81.3% 18.8%
		72.1% 27.9%	89.9% 10.1%	81.8% 18.2%	63.7% 36.3%	76.8% 23.2%	75.0% 25.0%	90.0% 10.0%	86.6% 13.4%	67.6% 32.4%	79.8% 20.2%
		Target Class					Target Class				

		Test Confusion Matrix					All Confusion Matrix				
		1	2	3	4	Accuracy	1	2	3	4	Accuracy
Output Class	1	193 19.5%	0 0.0%	22 2.2%	49 4.9%	73.1% 26.9%	905 18.2%	3 0.1%	99 2.0%	199 4.0%	75.0% 25.0%
	2	3 0.3%	226 22.8%	2 0.2%	3 0.3%	96.6% 3.4%	8 0.2%	1110 22.4%	16 0.3%	12 0.2%	96.9% 3.1%
	3	37 3.7%	30 3.0%	188 19.0%	42 4.2%	63.3% 36.7%	178 3.6%	122 2.5%	1026 20.7%	235 4.7%	65.7% 34.3%
	4	29 2.9%	1 0.1%	18 1.8%	149 15.0%	75.6% 24.4%	149 3.0%	5 0.1%	99 2.0%	794 16.0%	75.8% 24.2%
		73.7% 26.3%	87.9% 12.1%	81.7% 18.3%	61.3% 38.7%	76.2% 23.8%	73.0% 27.0%	89.5% 10.5%	82.7% 17.3%	64.0% 36.0%	77.3% 22.7%
		Target Class					Target Class				

b)



Tablo 4.6'da WPD öznitelik çıkartma metodu kullanılarak elde edilen açık-çevrim confusion matrisleri gösterilmektedir.

Tablo 4.6: WFB öznitelik çıkarma metodu kullanılarak elde edilen açık-çevrim confusion matrisi
a)Alfabeyi tersten sayma, Küp döndürme imajinasyonu, Sol kol hareketi ve Matematik işlemi zihinsel görevleri için b)Alfabeyi tersten sayma, Sağ el hareketi, Sol kol hareketi ve Matematik işlemi zihinsel görevleri için

a)

Output Class	1	2	3	4	
1	192 15.5%	3 0.2%	34 2.7%	52 4.2%	68.3% 31.7%
2	5 0.4%	277 22.3%	23 1.9%	29 2.3%	82.9% 17.1%
3	45 3.6%	30 2.4%	226 18.2%	46 3.7%	65.1% 34.9%
4	68 5.5%	0 0.0%	27 2.2%	183 14.8%	65.8% 34.2%
	61.9% 38.1%	89.4% 10.6%	72.9% 27.1%	59.0% 41.0%	70.8% 29.2%
Target Class	1	2	3	4	

b)

Output Class	1	2	3	4	
1	199 16.0%	16 1.3%	14 1.1%	29 2.3%	77.1% 22.9%
2	107 8.6%	282 22.7%	11 0.9%	10 0.8%	68.8% 31.2%
3	3 0.2%	4 0.3%	278 22.4%	40 3.2%	85.5% 14.5%
4	1 0.1%	8 0.6%	7 0.6%	231 18.6%	93.5% 6.5%
	64.2% 35.8%	91.0% 9.0%	89.7% 10.3%	74.5% 25.5%	79.8% 20.2%
Target Class	1	2	3	4	

Sonuç olarak, WPD öznitelik çıkartma metodu ile gerçekleştirilen sınıflandırmada, N1-N3 eğitim ve test veri kümesi için kapalı-çevrimde %77.3'lük, açık-çevrimde ise %70.8'lik sınıflandırma doğruluğu elde edilirken, N2-N4 eğitim ve test veri kümesi için kapalı-çevrimde %77.7'lik, açık-çevrimde ise %79.8'lik sınıflandırma doğruluğu elde edilmiştir.

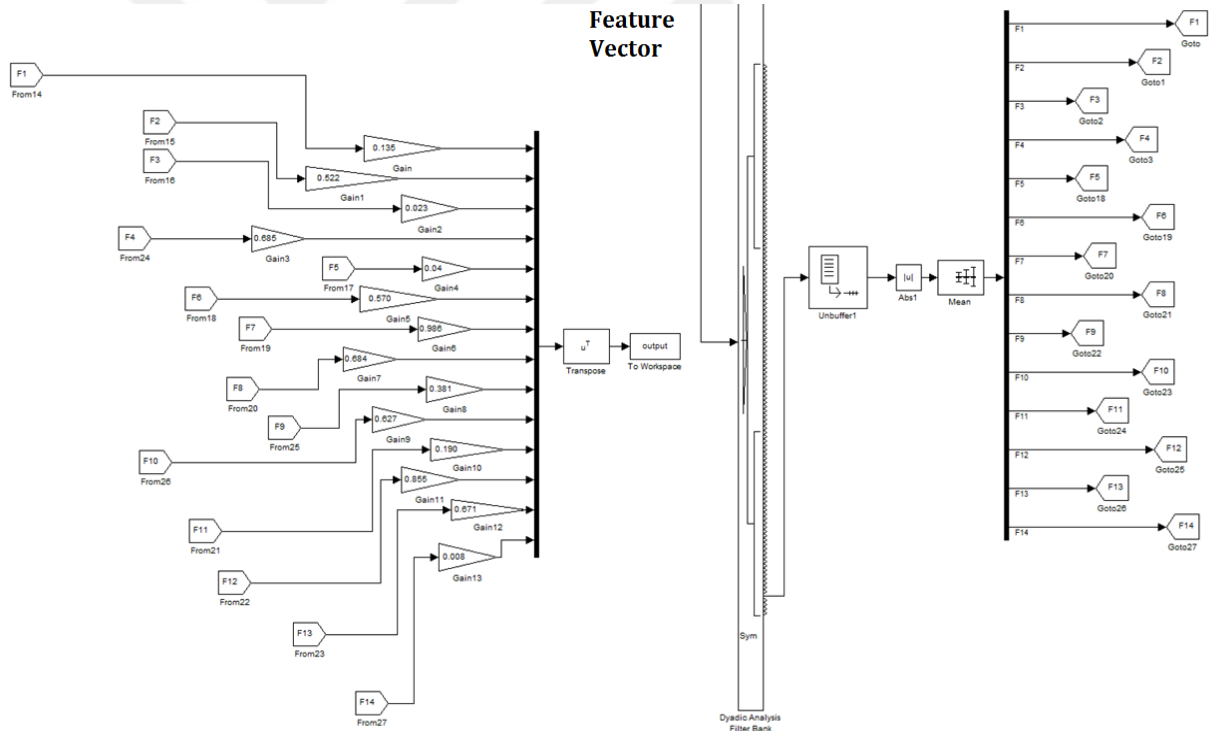

WFB öznitelik çıkartma metodu ile gerçekleştirilen sınıflandırmada ise, N1-N3 eğitim ve test veri kümesi için kapalı-çevrimde %89.6'lık, açık-çevrimde ise %79.4'lük sınıflandırma doğruluğu elde edilirken, N2-N4 eğitim ve test veri kümesi için kapalı-çevrimde %80.2'lik, açık-çevrimde ise %81.5'lik sınıflandırma doğruluğu elde edilmiştir.

Açık-çevrim doğruluk performansı üzerinden değerlendirme yapıldığında, %81.5 ile en yüksek sınıflandırma doğruluğuna sahip olan metod WFB'dir. Bu yüzden, gerçek-zamanlı BCI yörünge takibi simülasyonu için kullanılacak ve FS optimizasyonuna, PSO'ya tabi tutulacak olan, N2-N4 eğitim ve test veri kümesinin WFB metodu ile öznitelikleri çıkartılmış olan öznitelik vektörleridir. PSO sonucunda edilen öznitelik vektörlerine ilişkin ağırlıklar Tablo 4.7'de verilmiştir.

Tablo 4.7: PSO öznitelik seçimi sonuçları

ÖZDEĞER	AĞIRLIK
F7	0.986
F12	0.855
F4	0.685
F8	0.684
F13	0.671
F10	0.627
F6	0.57
F2	0.522
F9	0.381
F11	0.19
F1	0.135
F5	0.04
F3	0.023
F14	0.008

FS işleminin ardından öznitelik vektörleri ağırlıklandırılarak simülasyon üzerinde gerçek-zamanlı testler yapılmıştır ve açık-çevrim doğruluğu performansı %81.5'ten %82.94'e çıkartılmıştır. Kappa değeri 0.776 olarak hesaplanmıştır. Sistemin Matlab/Simulink modeli Şekil 4.1'de gösterilmiştir.



Şekil 4.1: BCI Matlab&Simulink modeli

Tablo 4.8'de WFB metodu ile öznelikleri çıkartılmış ve PSO ile FS yapılmış olan modelin açık-çevrim simülasyon sonucu gösterilmiştir.

Tablo 4.8: WFB öznitelik çıkartma metodu ve PSO öznitelik seçimi kullanılarak elde edilen açık-çevrim confusion matrisi

doğruluk: 82.94% +/-1.54% (mikro: 82.94%)					
	doğru 1	doğru 2	doğru 3	doğru 4	sınıf hassasiyeti
tahmin 1	1013	186	53	105	74.65%
tahmin 2	138	968	43	61	80%
tahmin 3	20	17	1100	41	93.38%
tahmin 4	69	69	44	1033	85.02%
sınıf doğruluğu	81.69%	78.06%	88.71%	83.31%	82.94%

Gerçek-zamanlı yörünge takibi işleminde, "Matlab&Simulink"te oluşturulan simülasyon modeli referans alınmıştır. Model, daha önce oluşturulan BCI ile haberleşecek şekilde ayarlanmıştır. BCI'deki obje, alfabenin tersten sayılması işlemi ile yukarıya, sağ elin hareket ettirilmesi işlemi ile sağa, sol kolun hareket ettirilmesi işlemi ile sola, matematiksel işlemlerin gerçekleştirilmesi ile aşağıya doğru hareket edilecek şekilde programlanmıştır. Gerçek-zamanlı simülasyon boyunca, verilen referans yörüngeyi takip edecek şekilde zihinsel görevler sırasıyla gerçekleştirilmiştir.

Gerçek-zamandaki tanımlama performansı, aşağıdaki formüle göre hesaplanır:

$$e_{\text{perfA}} = \frac{|\sum_{i=1}^n A(i) - n|}{n} * 100$$

$$e_{\text{perfRH}} = \frac{|\sum_{i=1}^n RH(i) - n|}{n} * 100$$

$$e_{\text{perfLA}} = \frac{|\sum_{i=1}^n LA(i) - n|}{n} * 100$$

$$e_{\text{perfM}} = \frac{|\sum_{i=1}^n M(i) - n|}{n} * 100$$

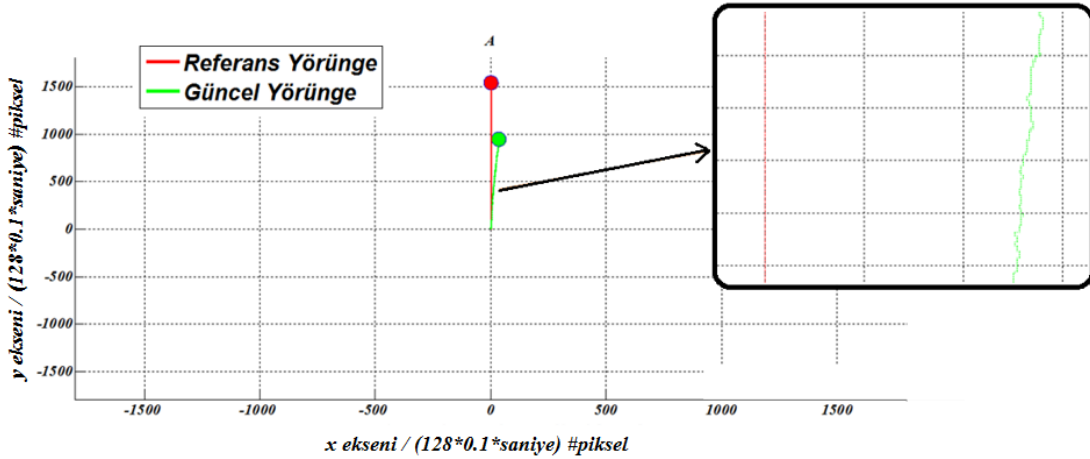
$$e_{\text{perf}} = \frac{(e_{\text{perfA}} + e_{\text{perfRH}} + e_{\text{perfLA}} + e_{\text{perfM}})}{4}$$

$$\text{Perf} = 100 - e_{\text{perf}}$$

Burada, "e" her bir sınıfa ilişkin sınıflandırma hatasını, e_{perf} ortalama performans hatasını ve "Perf" de yüzde sınıflandırma doğruluk değerini göstermektedir.


"n", her bir sınıfa ait, elde edilmiş matrisin toplam eleman sayısıdır.

Bu teste ilişkin sonuçlar sırasıyla; "A", "RH", "LA", "M", "A-RH", "A-LA", "RH-M", "LA-M", "A-RH-M", "A-LA-M", "RH-M-LA", "RH-A-LA" ve en sonunda da, bütün zihinsel görev sekanslarını; "A-RH-LA-M" kapsayacak biçimde, Şekil 4.2-4.14, arasında gösterilmiştir.




Şekil 4.2: "Alfabeyi tersten sayma", zihinsel görevine ilişkin gerçek-zamalı BCI yürüme takibi işlemi


Şekil 4.2'de büyütülmüş kesit, takip esnasında oluşan geri kalmanın sebebi olan yanlış sınıflandırmadan kaynaklanan hataları ve bunun sonucunda referans yörüngeden sapmaları göstermektedir. x ve y eksenlerine ait olan koordinat değerleri, hareket ettirilen nesnenin saniye başına 128 piksel bırakması ve piksellerin birbirleri arasında olan uzaklığın da 0.1 değerini alması, dikkate alınarak oluşturulmuştur.




Şekil 4.3: "Sağ el hareketinin düşünülmesi", zihinsel görevine ilişkin gerçek-zamalı BCI yürüme takibi işlemi




Şekil 4.4: "Sol kol hareketinin düşünülmesi", zihinsel görevine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi




Şekil 4.5: "Matematiksel işlemlerin yapılması", zihinsel görevine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi




Şekil 4.6: "Alfabeyi tersten sayma" ve "Sağ el hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi




Şekil 4.7: "Alfabeyi tersten sayma" ve "Sol kol hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi



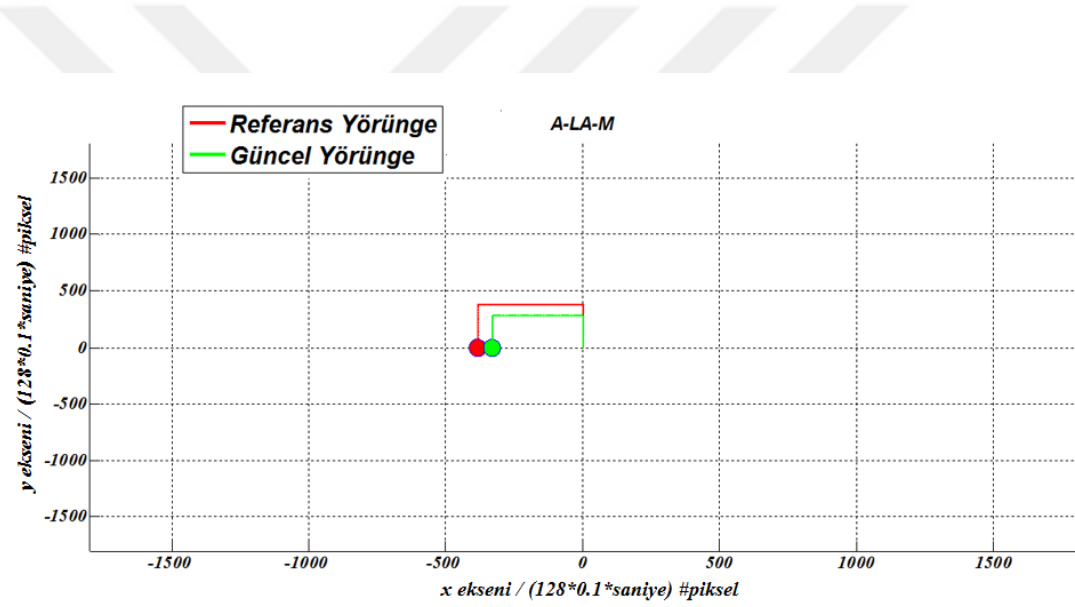
Şekil 4.8: "Sağ el hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamalı BCI yörünge takibi işlemi




Şekil 4.9: "Sol kol hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamalı BCI yörünge takibi işlemi




Şekil 4.10:"Alfabeyi tersten sayma", "Sağ el hareketinin düşünülmesi" ve "Matematikselleştirme", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi




Şekil 4.11:"Alfabeyi tersten sayma", "Sol kol hareketinin düşünülmesi" ve "Matematikselleştirme", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi



Şekil 4.12:"Sağ el hareketinin düşünülmesi", "Matematiksel işlemlerin yapılması" ve "Sol kol hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi



Şekil 4.13:"Sağ el hareketinin düşünülmesi", "Alfabeyi tersten sayma" ve "Sol kol hareketinin düşünülmesi", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi




Şekil 4.14:"Alfabeyi tersten sayma", "Sağ el hareketinin düşünülmesi", "Sol kol hareketinin düşünülmesi" ve "Matematiksel işlemlerin yapılması", zihinsel görevlerine ilişkin gerçek-zamanlı BCI yörünge takibi işlemi

Burada, yeşil çizgiler güncel yörüngeyi gösterirken, kırmızı çizgiler de, referans yörüngeyi göstermektedir. BCI'nın gerçek-zamandaki tanımlama performansları, yukarıda verilen performans kriteri hesaplamasına göre yalnızca "alfabeyi tersten sayma", zihinsel görevi için %74.8, "sağ el hareketinin düşünülmesi", zihinsel görevi için %88, "sol kol hareketinin düşünülmesi", zihinsel görevi için %86.4, "matematiksel işlemlerin yapılması", zihinsel görevi için %76.2 olarak elde edilirken; bu zihinsel görevlerin kombinasyonları için elde edilmiş test sonuçları Tablo 4.9'da gösterilmiştir.

Tablo 4.9: Zihinsel görevlerin kombinasyonları için elde edilmiş gerçek-zamanlı yörünge takibi performansları

SINIF	%PERFORMANS
A-RH	81.40%
A-LA	80.60%
RH-M	82.10%
LA-M	81.32%
A-RH-M	79.69%
A-LA-M	79.16%
RH-M-LA	83.56%
RH-A-LA	83.11%
A-RH-LA-M	81.38%


Zihinsel görevlerin birbirleri arasındaki ani deęişimlere, sistemin verdięi tepkiyi sınamak ve dinamik yörünge takibine ilişkin performansı tespit edebilmek amacı ile bu testlere ek olarak, yörünge takibinde karşılaşılan hataların, çoklu zihinsel görevler üzerinden gerçek-zamanda giderilmesine ve aktif, dinamik yörünge kontrolüne yönelik olarak testler yapılmıştır ve bu testler arasından elde edilen en iyi sonuç, Şekil 4.15'te gösterilmiştir.




Şekil 4.15: Çoklu zihinsel görev deęiştirilmesine dayalı gerçek-zamanlı yörünge takibi ve kontrolü işlemi

Bu testin sonucunda BCI'nın sınıflandırma performansı, NRMSE metodu ile hesaplanmıştır.

Sonuç olarak, çoklu zihinsel görev deęiştirilmesine dayalı gerçek-zamanlı yörünge takibine ilişkin NRMSE deęeri, 0.2818 olarak elde edilmiştir. Çoklu zihinsel görevlerin aktif olarak deęiştirilmesi yoluyla istenilen hedeflere ulaşma testine ilişkin sonuçlar, Şekil 4.17'de gösterilmiştir. Bu testin kısıtları arasında, Şekil 4.16'da gösterilen referans yolları takip etme şartı da vardır.



Şekil 4.16: Teste ait hedefler ve referans yollar



Şekil 4.17: Çoklu zihinsel görevlerin dinamik olarak değiştirilmesi yoluyla istenilen hedeflere ulaşılması

5. TARTIŞMA

Açık-çevrimde en yüksek sınıflandırma doğruluğu, %81.5 ile Symlet-2 dalgacığı tabanlı WFB metodu kullanılarak elde edilmiştir. Optimizasyon sonucunda sınıflandırma elde edilen sınıflandırma doğruluğu %82,94'tür. Gerçek-zamanda yapılan referans yörünge takibi testlerinde ise 4 zihinsel görev birlikte gerçekleştirildiğinde, %81.38'lik tanımlama performansı elde edilmiştir. Kappa değeri de 0.776'lık değer ile "çok iyi" kategorisindedir.

Çoklu zihinsel görev değiştirilmesine dayalı gerçek-zamanlı yörünge takibi, 0.2818'lik NRMSE değeri ile gerçekleştirilmiştir. Belirlenmiş hedeflere çoklu zihinsel görevlerinin birbiri ardınca değiştirilmesi yolu ile yörünge takibi kriterini de sağlayacak şekilde ulaşılmıştır.

EEG kontrollü robot kolunun yörünge planlaması amacıyla, sol ve sağ el hareketlerinin SVM sınıflandırıcı kullanılarak ve GA'ya dayalı yörünge planlaması yapılarak elde edilen sonuçlarda %75.77'lik bir sınıflandırma doğruluğu elde edilmiştir [74].

WT katsayılarına dayalı öznitelik çıkartma metotlarının güç özelliği katsayılarına dayalı öznitelik çıkartma metotlarından daha iyi sınıflandırma doğruluğu sağladığı görüşü de desteklenmiştir. 4 sınıflı motor imgelemine dayalı, Bayesian entegrasyon aracılığı ile oluşturulmuş EEG sınıflandırıcısının da hedefe ulaşma doğruluğunun %80 civarında olduğu tespit edilmiştir [75]. Sol ve sağ motor imgelemlerinin gerçek-zamanlı sınıflandırılmasına dönük olarak, statik ve adaptif ağırlıklandırılmış spektral spasyal şablon öznitelik çıkartma metotları kullanılarak yapılan deneylerde en iyi %88,9, en kötü %80.11'lik sınıflandırma doğruluğu elde edilmiştir. CSP metodu kullanılarak yapılan 4 sınıflı sınıflandırmada ise, %80,24 civarında sınıflandırma doğruluğuna ulaşılmıştır [76]. El hareketlerinin, 4 sınıf üzerinden BP özniteliklerinin LDA sınıflandırıcılarda sınıflandırılması işlemi [77], sensör uzayı çözümleme analizi [78], elin konumunun ve hızının regresyon metodu ile çözümlenmesi [79], çoklu öznitelik tabanlı meta sınıflandırıcı kullanılarak hedef lokasyonun çözümlenmesi [80], el hareketi hızlarının iki boyutlu çizim görevi boyunca Kalman filtresi ile çözümlenmesi [81] invazif olmayan BCI üzerinde yapılan benzer çalışmalar arasındadır.

Literatürdeki benzer çalışmalarla karşılaştırıldığında, bu tezin, elde edilen bulgular ve performans açısından doyurucu ve nitelikli olduğu görülmektedir.

6.SONUÇ VE ÖNERİLER

Bu tezin sonucunda; EEG sinyalleri kullanıcı üzerinden toplanmış, nörolojik aktiviteye ait veriler belirli bir algoritma içinde kodlanarak tespit edilmiş olup, bu sinyalleri dışsal bir mekatronik cihazın kontrol sinyallerine dönüştüren invazif metodolojiye gereksinim duymayan bir BCI sistemi tasarlanmıştır. Bu sistem, aynı zamanda zihinsel aktivitenin sınıflandırılmasında temel teşkil eden bir ölçme ve veri toplama aracı olarak da kullanılabilir ve bu sayede, fiziksel bir sistemin ve/veya bilgisayar tabanlı simülasyonların kontrol edilmesi sağlanabilir.

Bu tezde, öncelikle kullanıcıdan alınan EEG sinyalleri filtrelenip işlenerek WT ile frekans-zaman bileşenlerine ayrıştırılmıştır. Ardından, elde edilen yüksek boyutlu öznelik vektörleri PCA'ya tabi tutularak, öznelik indirgemesi işlemi gerçekleştirilmiştir. Daha sonra, frekans-zaman düzleminde çıkartılan indirgenmiş öznelik vektörleri ANN ile sınıflandırılmıştır. Elde edilen verilerin içerisinden sınıflandırma performansını arttırmak amacıyla, PSO'ya dayalı özellik seçimi yöntemi kullanılarak, kıymetli verinin seçilmesi işlemi yapılmıştır.

Birbirinden farklı temel zihinsel görevler (alfabeyi tersten sayma-zihinsel küp döndürme-sağ el hareketini düşünme-sol kol hareketini düşünme-matematiksel işlem gerçekleştirme) sınıflandırılmıştır. Kullanıcının, BCI üzerinde oluşturulmuş objeyi, hiyerarşik kontrol stratejisini kullanarak, 2 eksen üzerinden 4 farklı yönde (sağ-sol-yukarı-aşağı) hareket ettirmesi ve tanımlı referans yörünge takibi işlemleri gerçek-zamanda tatbik edilmiştir.

Sonuç olarak, kullanıcının, ilgili zihinsel aktiviteyi gerçekleştirdiği esnada üretilen beyin sinyalleri, EEG elektrotları tarafından ölçülmüş, bilgisayar programında işlenerek dış ortam ile etkileşen bir elektronik cihaz için komut/girdi sinyallerine etkin bir şekilde dönüştürülmüştür. Gerçek-zamanlı sınıflandırma algoritmalarının kullanılabilirliği araştırıldığında; her kullanıcı için, en uygun frekans bandının ve penceresinin seçilmesi, kullanıcıya özel BCI sistemlerinin tasarımı açısından elzemdir.

Geri yayımlı algoritmaya dayalı MLP ANN, sınıflandırma doğruluğu açısından kullanılabilir bir yöntem olmasına karşın, karmaşık yapısı nedeniyle işlem yükünü arttırmaktan dolayı, gerçek-zamanlı BCI uygulamalarında, en uygun tercih olmadığı

sonucuna varılmıştır. Bu bağlamda, dayanıklı ve kullanıcıdan bağımsız BCI sistemlerinin araştırılmasına ihtiyaç vardır.

İlerleyen çalışmalarda, sınıflandırma doğruluğunu daha da arttıracak metotların kombinasyonları üzerinde yoğunlaşılacaktır. Sınıf sayısının arttırılması durumunda karşılaşılan problemlerin üstesinden gelebilen, gerçek-zamanlı sınıflandırma doğruluğunu arttırıp işlem yükünü azaltan ve aynı zamanda spasyal boyut analizini de yapabilen rekabetçi algoritmalar denenecektir. Bu yöntemlere dayalı olarak geliştirilen BCI aracılığı ile, yapay eyleyici olan robotik manipülatöre ait kontrol sinyalleri gerçek-zamanda üretilecek ve robotun,düzlem üzerinde iki boyutlu hareketi sağlanacaktır.



7.KAYNAKLAR

- [1] A. Khorshidtalab and M. J. E. Salami. (2011) EEG signal classification for real-time brain-computer interface applications: A review, Mechatronics (ICOM), 2011 4th International Conference On, Kuala Lumpur, pp. 1-7.
- [2] Saeid Sanei, J.A.Chambers. (2007) EEG Signal Processing, John Wiley&Sons.
- [3] Kandel, E. R., Schwartz, J. H. 1., & Jessell, T. M. (2000) Principles of neural science (4th ed.). New York: McGraw-Hill, Health Professions Division.
- [4] Oğuz Tanrıdağ. (2015) Temel Beyin Bilgisine ve Nöro-Davranışsal Sendromlara Giriş. Nobel Tıp Kitabevi.
- [5] Felix, Lee., Sherer R., Leeb R., Neuper C., Horst B., Pfurtscheller G. (2005) A comparative Analysis of Multi-Class EEG Classification for Brain Computer Interface. Proceedings of the 10th Computer Vision Winter Workshop.
- [6] Kavita Mahajan, Rajput Sangita M. (2012) A Comparative study of ANN and SVM for EEG Classification. International Journal of Engineering Research & Technology, Vol.1-Issue 6.
- [7] Hyvärinen A., Oja E. (1997) A Fast Fixed-Point Algorithm for Independent Component Analysis. Neural Computing, 9, pp.1483–1492.
- [8] Suleiman, A. B. R., and Fatehi, T. A. H. (2007) Features Extraction Techniques of EEG Signal for BCI Applications. Mosul: Faculty of Computer and Information Engineering, Department College of Electronics Engineering, University of Mosul.
- [9] S. V. Notley and S. J. Elliott. (2003) Efficient estimation of a time-varying dimension parameter and its application to EEG analysis, IEEE Transactions on Biomedical Engineering, vol. 50, no. 5, pp. 594-602.
- [10] Damien Coyle, Girijesh Prasad, T. M. McGinnity. (2005) A Time-Frequency Approach to Feature Extraction for a Brain-Computer Interface with a Comparative Analysis of Performance Measures. EURASIP Journal on Advances in Signal Processing, Volume 2005, Number 19, Page 1.

- [11] Helle Henriksen. (2012) A Generative Approach to EEG Source Separation, Classification and Artifact Correction. Thesis (MSc). Technical University of Denmark.
- [12] Büssow. Richard. (2007) An algorithm for the continuous Morlet wavelet transform, AA(Institute of Fluid Mechanics and Engineering Acoustics, Berlin University of Technology, Mechanical Systems and Signal Processing, Volume 21, Issue 8, p.2970-2979.
- [13] Paul S Addison. (2002) The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance, CRC Press.
- [14] Christopher Liner. (2010) An overview of wavelet transform concepts and applications, University of Houston.
- [15] Costanza D'Avanzo, Vincenza Tarantino, Patrizia Bisiacchi, Giovanni Sparacino. (2009) A wavelet Methodology for EEG Time-frequency Analysis in a Time Discrimination Task. International Journal of Bioelectromagnetism, Vol. 11, No.4, pp.185-188.
- [16] Y. T. Qassim, T. Cutmore, D. James and D. Rowlands. (2012) FPGA implementation of Morlet continuous wavelet transform for EEG analysis, Computer and Communication Engineering (ICCCE), International Conference on, Kuala Lumpur, pp. 59-64.
- [17] Daniela Iacoviello, Andrea Petracca, S. Matteo, P. Giuseppe. (2015) A real-time classification algorithm for EEG-based BCI driven by self-induced emotions. Computer Methods and Programs in Biomedicine, Vol. 122, Issue 3, Pages 293-303.
- [18] Michael Weeks. (2010) Digital Signal Processing Using MATLAB & Wavelets, Second Edition, Jones and Bartlett Publishers.
- [19] Alexander Lenhardt. (2011) A Brain-Computer Interface for Robotic Arm Control. Biefeld.
- [20] Stéphane Mallat. (2008) A Wavelet Tour of Signal Processing, 3rd ed. Academic Press.
- [21] K. Ramchandran, M. Vetterli and C. Herley. (1996) Wavelets, subband coding, and best bases, in Proceedings of the IEEE, vol. 84, no. 4, pp. 541-560.

- [22] Paul Tobin, Edward Jones. (1998) Classification of Electroencephalograph Signals using Wavelet Transforms and Neural Networks, Dublin Institute of Technology.
- [23] Canal M.R. (2010) Comparison of wavelet and short time Fourier transform methods in the analysis of EMG signals, Journal of Medical Systems, 34 (1) 91 - 94.
- [24] K. Ranjeet, A. Kuamr, Rajesh K. Pandey. (2012) ECG Signal Compression using Optimum Wavelet Filter Bank Based on Kaiser Window, International Conference on Modelling Optimization and Computing, 2889–2902.
- [25] Khushaba, R.N. Kodagoda, S. Lal, S. Dissanayake, G. (2011). Driver Drowsiness Classification Using Fuzzy Wavelet-Packet-Based Feature-Extraction Algorithm, in Biomedical Engineering, IEEE Transactions on, 58 (1) 121-131.
- [26] F. Faradji, R. K. Ward and G. E. Birch. (2009) A brain-computer interface based on mental tasks with a zero false activation rate, 4th International IEEE/EMBS Conference on Neural Engineering, Antalya, 2009, pp. 355-358.
- [27] F. Faradji, R. K. Ward and G. E. Birch. (2009) A custom-designed mental task-based brain-computer interface, IEEE International Conference on Acoustics, Speech and Signal Processing, Taipei, 2009, pp. 529-532.
- [28] Derviş Karaboğa. (2014) Yapay Zeka Optimizasyon Algoritmaları, Nobel Akademik Yayıncılık.
- [29] Muhammet Ünal. (2008) PID Kontrolörün Karınca Koloniası/Genetik Algoritma Tabanlı Optimizasyonu ve GUNT RT 532 Basınç Prosesinin Kontrolü, Tez (MSc.). Marmara Üniversitesi.
- [30] Goldberg, D. E.; Sastry, K. (2001) A Practical Schema Theorem For Genetic Algorithms Design and Tuning, University of Illinois.
- [31] Biroğul, S. (2005) Genetik Algoritma Yaklaşımıyla Atölye Çizelgeleme, Fen Bilimleri Enstitüsü, Tez (MSc.), Ankara Gazi Üniversitesi.
- [32] Y.-T. Hsiao, C.-L. Chuang, and C.-C. Chien. (2004) Ant Colony Optimization For Designing of PID Controllers, International Symposium on Computer Aided Control Systems Design, Taiwan.

- [33] Ergüzel T. (2009) Sıvı Seviye Kontrolü İçin Bulanık Kontrolör Parametrelerinin Karınca Koloni ve Genetik Algoritma ile Optimizasyonu, TOK, İstanbul.
- [34]Colormi, A., Dorigo, M., Maniezzo, V. (1992) Distributed Optimization by Ant Colonies, The First European Conference on Artificial Life, Paris, France.
- [35] Enrique Hortal, Andres Ubeda, Eduardo Ianez, Jose M. Azorin. (2014) Control of a 2 DoF robot using a Brain-Machine Interface, Computer Methods and Programs in Biomedicine, Volume 116, Issue 2, Pages 169-176.
- [36] Shannon, C. E. (1948) A Mathematical Theory of Communication. Bell System Technical Journal, 27: 379–423.
- [37] P.V.Arun. (2014) A Comparative Analysis on the Applicability of Entropy in remote sensing, Journal of the Indian Society Remote Sensing, Vol. 42, Issue 1, pp 217-226.
- [38] Kay, S. M. (1988) Modern Spectral Estimation: Theory and Application, Prentice-Hall, Englewood Cliffs, New Jersey.
- [39] Yu Hen Hu, Jenq-Neng Hwang. (2001) Handbook of Neural Network Signal Processing, CRC Press.
- [40] Kanhouche, Rami. (2003) A Modified Burg Algorithm Equivalent In Results to Levinson Algorithm, ArXiV.
- [41] Ethem Alpaydın. (2011) Yapay Öğrenme, Boğaziçi Üniversitesi Yayınevi.
- [42]Elly Matul Imah, Faris Al Afif, M. Ivan Fanany, W. Jatmiko and T. Basaruddin, (2011) A comparative study on Daubechies Wavelet Transformation, Kernel PCA and PCA as feature extractors for arrhythmia detection using SVM, TENCON 2011 - 2011 IEEE Region 10 Conference, Bali, pp. 5-9.
- [43] Mohammad A. Rahman, Wanli Ma, Dat Tran, John Campbell. (2012) A Comprehensive Survey of the Feature Extraction Methods in the EEG Research, Algorithms and Architectures for Parallel Processing, Vol. 7440, pp 274-283.
- [44]Z. Zhang, X. Li and Z. Deng. (2010) A CWT-based SSVEP classification method for brain-computer interface system, Intelligent Control and Information Processing (ICICIP), International Conference on Dalian, pp. 43-48.

- [45] G. Pfurtscheller. (2001) Functional brain imaging based on ERD/ERS, *Vision Research*, Vol. 41, Issues 10-11, Pages 1257-1260.
- [46] Ernst Niedermeyer, F. H. Lopes da Silva. (2004) *Electroencephalography: Basic Principles, Clinical Applications and Related Fields*, Lippincott Williams & Wilkins
- [47] Christa Neuper, Wolfgang Klimesch. (2000) *Event-Related Dynamics of Brain Oscillations*, 1st Edition, Elsevier Science.
- [48] Case H. Vanderwolf. (2003). *An Odyssey Through the Brain, Behavior and the Mind*, Springer.
- [48] G. Srivastava, S. Crottaz-Herbette, K.M Lau, Glover, G.H., Menon, V. (2005) ICA-based procedures for removing ballistocardiogram artifacts from EEG data acquired in the MRI scanner, *NeuroImage* 24, 50–60.
- [49] V. Jeybalan, A. Samraj, L. Chu Kiong. (2008) Motor Imaginary Signal Classification using Adaptive Recursive Bandpass Filter and Adaptive Autoregressive Models for Brain Machine Interface Designs, *International Journal of Biological and Medical Sciences*.
- [50] E. Haselsteiner and G. Pfurtscheller. (2000) Using time dependent neural networks for EEG classification, *IEEE Trans. Rehab. Eng.*, vol. 6, 457–463.
- [51] D. Coyle, G. Prasad and T M. McGinnity. (2004) Extracting features for a brain–computer interface by self-organising fuzzy neural network-based time series prediction, *Proc. 26th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*, San Francisco, CA 4371–4.
- [52] Steven Lemm, Klaus-Robert Müller, Gabriel Curio. (2009) A Generalized Framework for Event-Related Desynchronization (ERD),
- [53] Chen CC. , Hsu CY, Chiu HW, Hu CJ, Lee TC. (2015) Frequency power and coherence of electroencephalography are correlated with the severity of Alzheimer's disease: A multicenter analysis in Taiwan
- [54] X. Zhao, D. Li, B. Yang, C. Ma. (2014) Feature selection based on improved ant colony optimization for online detection of foreign fiber in cotton, *Applied Soft Computing* 24 585–596.
- [55] L. Huan, H. Motoda. (2000) *Feature Selection for Knowledge Discovery and Data Mining*, Springer, New York

- [56] T.T. Erguzel, S.Ozekes, O. Tan, S. Gultekin. (2014) Feature Selection and Classification of Electroencephalographic Signals: An Artificial Neural Network and Genetic Algorithm Based Approach, *Clinical EEG Neuroscience*.
- [57] S.F.Yuan,F.L.Chu. (2007) Faultdiagnosisbasedonsupportvectormachineswith parameteroptimizationbyartificial immunizationalgorithm, *MechSyst. Signal Process.*2, 1318–1330.
- [58]X.L. Zhang,X.F.Chen,Z.J.He. (2007), AnACO-basedalgorithmforparameter optimizationofsupportvector machines, *Expert Syst.Appl.*37, 6618–6628.
- [59] F.F.Chen,B.P.Tang,R.X.Chen. (2007) Anovelfaultdiagnosismodelforgearbox based onwaveletsupportvectormachinewithimmunegenetic algorithm, *Measurement* 46, 220–232.
- [60] J. Huang,X.G.Hu,F.Yang. (2011)Supportvectormachinewithgeneticalgorithmfor machinery faultdiagnosisofhighvoltagecircuitbreaker,*Measurement* 44, 1018–1027.
- [61] T.T. Erguzel, C. Tas, M. Cebi. (2015)A wrapperbasedapproachforfeatureselectionandclassification of majordepressedisorder–bipolar disorders, *Computers inBiologyandMedicine*64,127–137.
- [62] M. H. Aghdam, N. Ghasem-Aghaee, M. Ehsan Basiri. (2009) Text feature selection using ant colony optimization, *Expert Systems with Applications* 36, 6843–6853.
- [63] Y. Saeys, I. Inza, P. Larranaga. (2007) A review of feature selection techniques in bioinformatics,*Bioinformatics* 23, 2507–2517.
- [64] R.M. RizkAllah, M. Elsayed Zaki, A. Ahmed El-Sawy. (2013) Hybridizing ant colony optimization with firefly algorithm for unconstrained optimization problems, *Applied Mathematics and Computation* 224, 473–483
- [65] Andries P.Engelbrecht. (2005) *Fundamentals of Computational Swarm Intelligence*, Wiley.
- [66] Viera AJ, Garrett JM. (2005), *Understanding Interobserver Agreement: The Kappa Statistic*. *Society of Teachers of Family Medicine*, 37(5): p. 360-363.
- [67] Dawson-Saunders B, Trapp Robert G. (1994) *Basic&Clinical Biostatistics*, London, 32-33,116.
- [68] İstatistiksel Kalite Kontrol, Sorularla Resmi İstatistikler Dizisi - 11, TÜİK.
- [69] Du,S; Vuskovic M. (2004) Temporal vs Spectral Approach to Feature Extraction from Prehensile EMG Signals, *Information Reuse and Integration*

- [70] McLachlan, G.J. Basford, Kayer E. (1988) Mixture Models: Inference and Applications to Clustering, M. Dekker, New York, N.Y.
- [71] McLachlan, G; Peel, D. (2004) Finite Mixture Models, Wiley.
- [72] Melnykov, Volodymyr; Maitra, Ranjan. (2010) Finite mixture models and model-based clustering. *Statist. Surv.* 4, 80.
- [73] Dave Kessler and Allen McDowell. (2012) Introducing the FMM Procedure for Finite Mixture Models, SAS Institute Inc., Cary, NC
- [74] Rinku Roy, M. Mahadevappab, C.S.Kumar (2015) Trajectory path planning of EEG controlled robotic arm using GA, 7th International conference on Intelligent Human Computer Interaction, IHCI 2015
- [75] X. Dong, H. Wang, Z. Chen and B. E. Shi. (2015) Hybrid Brain Computer Interface via Bayesian integration of EEG and eye gaze, 7th International IEEE/EMBS Conference on Neural Engineering (NER), Montpellier, 2015, pp. 150-153.
- [76] Vinod A. Prasad. (2014) Robust BCI Algorithms for Motor Imagery Classification and Upper Limb Kinematics Decoding, Nanyang Technological University, Singapore.
- [77] S. Waldert, H. Preissl, E. Demandt, C. Braun, N. Birbaumer, A. Aertsen, and C. Mehring, (2008) Hand movement direction decoded from MEG and EEG, *The Journal of Neuroscience*, vol. 28, pp. 1000-1008.
- [78] W. Wang, G. P. Sudre, Y. Xu, R. E. Kass, J. L. Collinger, A. D. Degenhart, A. I. Bagic, and D. J. Weber. (2010) Decoding and cortical source localization for intended movement direction with MEG, *Journal of Neurophysiology*, vol. 104, pp. 2451-2461.
- [79] T. J. Bradberry, J. L. Contreras-Vidal, and F. Rong. (2008) Decoding hand and cursor kinematics from magnetoencephalographic signals during tool use, 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 530.
- [80] P. S. Hammon, S. Makeig, H. Poizner, E. Todorov, and V. R. De Sa. (2008) Predicting reaching targets from human EEG, *Signal Processing Magazine, IEEE*, vol. 25, pp. 69-77.

[81] J. Lv and Y. Li, Decoding. (2010)hand movement velocities from EEG signals during a continuous drawing task," in Fuzzy Systems and Knowledge Discovery (FSKD), Seventh International Conference onpp. 2186-2189.

[82] Noran M. El-Kafrawy, Doaa Hegazy, Mohamed Fahmy Tolba. (2014). Features Extraction and Classification of EEG Signals Using Empirical Mode Decomposition and Support Vector Machine. Advanced Machine Learning Technologies and Applications, Vol.488, pp 189-198.



EK 1

Matlab GUI'de oluşturulmuş BCI kodu

```
function varargout = OpGUI(varargin)

gui_Singleton = 1;

gui_State = struct('gui_Name',    mfilename, ...
'gui_Singleton', gui_Singleton, ...
'gui_OpeningFcn', @OpGUI_OpeningFcn, ...
'gui_OutputFcn', @OpGUI_OutputFcn, ...
'gui_LayoutFcn', [], ...
'gui_Callback', []);
if nargin && ischar(varargin{1})
gui_State.gui_Callback = str2func(varargin{1});
end
if nargin
[varargout{1:nargin}] = gui_mainfcn(gui_State, varargin{:});
else
gui_mainfcn(gui_State, varargin{:});
end

% --- Executes just before OpGUI is made visible.
function OpGUI_OpeningFcn(hObject, eventdata, handles, varargin)
handles.output = hObject;
handles.get_data = @get_data;
% Update handles structure
guidata(hObject, handles);
function varargout = OpGUI_OutputFcn(hObject, eventdata, handles)
varargout{1} = handles.output;

global x y source pos
global DirectionLeft
global DirectionUp
global DirectionRight
global DirectionDown
global A C L A M
```

```

p = uipanel('Position',[.2 .2 .75 .75]);
source = uicontrol(p,'Style','PushButton',...
'Units','normalized',...
'String','Push Button',...
'Position',[.1177557+.0000193+.0000135 .13+.0275562 0.065
0.05],'backgroundcolor',[1 1 0],'string',['Source']);
pos=getpixelposition(source);
target = uicontrol(p,'Style','PushButton',...
'Units','normalized',...
'String','Push Button',...
'Position',[.9 .9 0.03 0.03],'backgroundcolor',[1 1 1],'string',['Target']);
x=0;
y=0;
DirectionLeft=1;
DirectionUp=2;
DirectionRight=3;
DirectionDown=4;
str=get(handles.editbox, 'string');
A= str2double(str);
str=get(handles.editbox4, 'string');
M= str2double(str);
str=get(handles.editbox2, 'string');
C= str2double(str);
str=get(handles.editbox3, 'string');
LA= str2double(str);
% [1=left;2=up;3=right;4=down];
% Generation of Target
%pause on;
function editbox_Callback(hObject, eventdata, handles)
global A
str=get(handles.editbox, 'string');
A= str2double(str);

```

% --- Executes during object creation, after setting all properties.

function editbox_CreateFcn(hObject, eventdata, handles)

if ispc && isequal(get(hObject, 'BackgroundColor'),

get(0, 'defaultUicontrolBackgroundColor'))

set(hObject, 'BackgroundColor', 'white');

end

function editbox2_Callback(hObject, eventdata, handles)

global C

str=get(handles.editbox2, 'string');

C= str2double(str);

function editbox2_CreateFcn(hObject, eventdata, handles)

if ispc && isequal(get(hObject, 'BackgroundColor'),

get(0, 'defaultUicontrolBackgroundColor'))

set(hObject, 'BackgroundColor', 'white');

end

function editbox3_Callback(hObject, eventdata, handles)

global LA

str=get(handles.editbox3, 'string');

LA= str2double(str);

function editbox3_CreateFcn(hObject, eventdata, handles)

if ispc && isequal(get(hObject, 'BackgroundColor'),

get(0, 'defaultUicontrolBackgroundColor'))

set(hObject, 'BackgroundColor', 'white');

end

function editbox4_Callback(hObject, eventdata, handles)

global M

str=get(handles.editbox4, 'string');

M= str2double(str);

function editbox4_CreateFcn(hObject, eventdata, handles)

if ispc && isequal(get(hObject, 'BackgroundColor'),

get(0, 'defaultUicontrolBackgroundColor'))

set(hObject, 'BackgroundColor', 'white');

end

```

function figure1_CreateFcn(hObject, eventdata, handles)
set_param(gcbh,'Userdata',hObject);
function UP_Callback(hObject, eventdata, handles)
global DirectionUp
global y source pos
if DirectionUp==2
if pos(2)~=1&&pos(2)<665
y=y+1;
setpixelposition(source,pos + [0 y 0 0]);
pos=pos+[0 y 0 0];
end
end
function RIGHT_Callback(hObject, eventdata, handles)
global x source pos
global DirectionRight
if DirectionRight==3
if pos(1)~=1&&pos(1)<1265
x=x+1;
setpixelposition(source,pos + [x 0 0 0]);
pos=pos+[x 0 0 0];
end
end
function LEFT_Callback(hObject, eventdata, handles)
global DirectionLeft
global x source pos
if DirectionLeft==1
if pos(1)~=1&&pos(1)>0
x=x+1;
setpixelposition(source,pos + [-x 0 0 0])
pos=pos+[-x 0 0 0];
end
end

```

```

function DOWN_Callback(hObject, eventdata, handles)
global DirectionDown
global y source pos
if DirectionDown==4
if pos(2)~=1&&pos(2)>0
y=y+1;
setpixelposition(source,pos + [0 -y 0 0]);
pos=pos+[0 -y 0 0];
end
end

function START_Callback(hObject, eventdata, handles)
global A C L A M
str=get(handles.editbox, 'string');
A= str2double(str);
str=get(handles.editbox4, 'string');
M= str2double(str);
str=get(handles.editbox2, 'string');
C= str2double(str);
str=get(handles.editbox3, 'string');
LA= str2double(str);
while(1)
if A==1
import java.awt.Robot;
import java.awt.event.*;
robot=Robot();
robot.mouseMove(1589,951);
robot.mousePress(InputEvent.BUTTON1_MASK);
robot.mouseRelease(InputEvent.BUTTON1_MASK);
elseif M==1
import java.awt.Robot;
import java.awt.event.*;
robot=Robot();
robot.mouseMove(1689,1009);

```


ÖZGEÇMİŞ



Adı Soyadı: Çağlar UYULAN

Doğum Yeri ve Tarihi: İzmir, 20.03.1985

Yabancı Dili: İngilizce

İletişim (Telefon/e-posta): caglaruyulan1@gmail.com

Eğitim Durumu (Kurum ve Yıl)

Lise: Bornova Anadolu Lisesi, Haziran-2003

Lisans: Dokuz Eylül Üniversitesi, Makina Mühendisliği, Haziran-2008

Yüksek Lisans: İstanbul Teknik Üniversitesi, Mekatronik Mühendisliği, Temmuz-2010

Çalıştığı Kurum/Kurumlar ve Yıl:


İstanbul Teknik Üniversitesi_Mekatronik Eğitim ve Araştırma Merkezi, Proje Asistanı,
Haziran-2009/Temmuz-2010

ENEKO Havalandırma ve Isı Ekonomisi Sistem Teknolojileri Makina San. ve Tic. A.Ş
Analiz Mühendisi, Ekim-2011/Temmuz-2012

İstanbul Teknik Üniversitesi, Araştırma Görevlisi, Mayıs-2014 /...

Yayımları (SCI ve diğer):

Uyulan, C. & Erguzel, T. T. (0) Comparison of Wavelet Families for Mental Task Classification. The Journal of Neurobehavioral Sciences, Online First: 30 May, 2016.



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZ SAVUNMA SINAVI TUTANAĞI

GENEL BİLGİLER

Öğrenci No	: 144202002
Öğrenci Adı Soyadı	: Çağlar UYULAN
Anabilim Dalı	: Nörobilim
Tez Danışmanı	: Yrd.Doç.Dr.Türker Tekin ERGÜZEL
Tezin Başlığı	: İki serbestlik dereceli hareket kontrolü için zihinsel görev sınıflandırma tabanlı beyin bilgisayar arayüzü tasarımı

Toplantı Tarihi	: 01.07.2016	Saati	: 10:00
Öğrenci Savunmaya	: <input checked="" type="radio"/> GELDI		
Üniversitemiz Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca tez bilimsel olarak incelenmiş, adayın tez çalışmasını sunmasının ardından, adaya tez çalışması ile ilgili sorular yöneltilmiştir.			
<input checked="" type="radio"/> Yapılan savunma sınavında adayın tez çalışması başarılı bulunarak KABUL edilmesine,			
<input type="radio"/> Yapılan savunma sınavı sonunda tez çalışmasının DÜZELTİLMESİNE , düzeltme için adaya ay EK SÜRE verilmesine (<i>en fazla 3 ay</i>)			
<input type="radio"/> Yapılan savunma sınavının sonunda tezin REDDEDİLMESİNE			
<input checked="" type="radio"/> OY BİRLİĞİ <input type="radio"/> OY ÇOKLUGU			
ile karar verilmiştir.			
Savunmada Tezin Başlığı	: <input checked="" type="radio"/> Değişmedi.	<input type="radio"/> Değişti.	
Tezin Yeni Başlığı	: —		
Öğrenci Savunmaya	: <input type="radio"/> GELMEDI		
Üniversitemiz Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca yukarıda belirtilen tarih ve saatte Tez Savunma Jürisi toplanmış ancak ilgili öğrenci savunma sınavına gelmemiştir. Adayın tez çalışmasını Jüri önünde sunmadığı için yapılan değerlendirmeler sonunda adayın tez çalışmasıyla ilgili aşağıdaki kararı,			
<input type="radio"/> OY BİRLİĞİ ile REDDEDİLMİŞTİR.			

Tez Sınavı Jürisi	Unvanı, Adı Soyadı	İmza
Başkan	Yrd.Doç.Dr. Ümit Toş	
Danışman Üye	Yrd.Doç.Dr. Türker Ergüzel	
Üye	Yrd.Doç.Dr. Belkıs Atasöver Anşın	
Üye		
Üye		

(Tüm durumlarda jüri üyelerinin tez değerlendirme raporları gerekir.)

Tarih : / / 20

Sayı No :

Yukarıda kimlik bilgileri belirtilen ve Anabilim Dalımız Yüksek Lisans Programı öğrencisinin Tez Savunma Sınav Tutanağı ve eklerinin Enstitü Yönetim Kurulunda görüşülmesi hususunda bilgilerinizi ve gereğini arz ederim.

.....
Anabilim Dalı Başkanı

Not : Bu forma orijinal raporlar (bir nüsha) eklenecektir.