

**PSİKOFİZYOLOJİK ÖLÇÜM TABANLI BEYİN
BİLGİSAYAR ARAYÜZ SİSTEMLERİNDE
PERFORMANS ARTIRMAYA YÖNELİK BİR
ÇALIŞMA**

**2018
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

Erdem ERKAN

**PSİKOFİZYOLOK ÖLÇÜM TABANLI BEYİN BİLGİSAYAR ARAYÜZ
SİSTEMLERİNDE FERFORMANS ARTIRMAYA YÖNELİK BİR ÇALIŞMA**

Erdem ERKAN

Karabük Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalında

Doktora Tezi

Olarak Hazırlanmıştır

KARABÜK

Temmuz 2018

Erdem ERKAN tarafından hazırlanan “PSİKOFİZYOLOJİK ÖLÇÜM TABANLI BEYİN BİLGİSAYAR ARAYÜZ SİSTEMLERİNDE PERFORMANS ARTIRMAYA YÖNELİK BİR ÇALIŞMA” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Prof. Dr. Mehmet AKBABA

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı



Bu çalışma, jürimiz tarafından oy birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 13/07/2018

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. İlhami Muharrem ORAK (KBÜ)



Üye : Prof. Dr. Mehmet AKBABA (KBÜ)



Üye : Doç. Dr. Ergin YILMAZ (ZBEÜ)



Üye : Dr. Öğr. Ü. Yasemin GÜLTEPE (KÜ)



Üye : Dr. Öğr. Ü. Burhan SELÇUK (KBÜ)



...../...../2018

KBÜ Fen Bilimleri Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Filiz ERSÖZ

Fen Bilimleri Enstitüsü Müdürü V.





“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Erdem ERKAN

ÖZET

Doktora Tezi

PSİKOFİZYOLOJİK ÖLÇÜM TABANLI BEYİN BİLGİSAYAR ARAYÜZ SİSTEMLERİNDE PERFORMANS ARTIRMAYA YÖNELİK BİR ÇALIŞMA

Erdem ERKAN

Karabük Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Prof. Dr. Mehmet AKBABA

Temmuz 2018, 87 sayfa

Nörolojik koşullara veya nörodejeneratif hastalıklara maruz kalmış insanlar nöral yollarla kendi kaslarını kontrol edemezler. Beyin bilgisayar arayüzü (BBA) sistemleri bu insanlara kendi sinir yollarından başka alternatif bir yol sunar. Bu alternatif yol, herhangi bir vokal kas kullanmadan BBA sistemleri aracılığı ile beyin sinyallerinin doğrudan kullanılmasıdır. Bir BBA sistemi beyin sinyallerinin elde edilmesi, işaretin yorumlanması ve sistem çıktısı olarak üç ana başlık altında incelenebilir. Sistem çıktısı başka bir cihazın kontrolü veya bilgisayar ekranında oluşan kelime dizileri olarak karşımıza çıkabilir. Beyin sinyalleri, sinyalin toplanması sırasında, sinyal algılayıcının (elektrot) beyin dokusuna olan uzaklığına göre farklılıklar göstermektedir. Kafa derisi üzerinden elektrotlar aracılığıyla elde edilen Elektroensefalografi (EEG) en yaygın kullanılan sinyal tipidir. Elektrokortikografi (ECoG) bir başka şekilde, invazive olarak, beyin dokusu üzerine alıcıların yerleştirilmesi ile elde edilen beyin sinyali tipidir. Her ne kadar ECoG

sinyalleri daha yüksek çözünürlüğe sahip olsa da EEG sinyalleri de BBA sistemleri için yeterli çözünürlüğe sahiptir. Yine beyinden elde edilen sinyaller, sinyale özgü birtakım farklılıklar göstermektedir. Bu farklılıklar örnek olarak hareket-harekete hazırlık öncesinde veya harici görsel-işitsel uyarılar sonucu oluşabilir. Hareket ile ilgili beyin sinyalleri Motor Imaginary (MI) olarak adlandırılırken, görsel uyarılarla oluşan beyin sinyalleri P300 (Pozitif 300) ve SSVEP (Steady State Visual Evoked Potential) olarak sınıflandırılabilirler. Tezde ECoG ve EEG tipi MI çalışmaları hazır ve özgün veri setleri ile, EEG tipi SSVEP çalışmalarda da tamamıyla özgün veri setleri kullanılarak gerçekleştirilmiştir. MI sinyalleri, hareket-harekete hazırlık öncesinde veya hareket hayali sırasında oluşan ve genelde beyin motor bölgesinden elde edilen sinyal tipidir. SSVEP sinyalleri, sabit frekansta bir kaynağa bakıldığında, beyin görme bölgesinden elde edilen benzer frekanstaki sinyallere karşılık gelir.

Bu tez çalışmasında BBA sistemlerinde performans artırmaya ve iyileştirmeye yönelik yöntemlerin geliştirilmesi amaçlanmıştır. Sinyal işleme yönelik algoritmaların yanı sıra, basit ve kullanıcı dostu sistem tasarımlarının da performans üzerine etkisi mevcuttur. Bu yüzden çalışmada sinyal işleme yöntemlerine ek olarak BBA sistem tasarımına da odaklanılmıştır. Çalışmada ilk olarak, BBA sistemlerine ilişkin deneyim kazanmak için, güncel sınıflandırma yöntemleri ve hazır veri setleri üzerinde çalışmalar yapılmıştır. Bu ilk çalışmada, beyinden üretilen MI tabanlı ECoG sinyallerinin sınıflandırılması gerçekleştirilmiştir. Çalışmada kullanılan veriler BCI Competition III'de kullanılan 1 numaralı veri setinden temin edilmiştir. İşlem yükünü azaltmak için öncelikle ayrıştırma başarısı düşük olan kanallar elenerek kanal sayısı azaltılmıştır. Optimal kanal setinin hızlı bir şekilde belirlenmesi için görsel kanal seçimi temelli Arc Detection Algorithm (ADA) algoritması geliştirilmiştir. Matematiksel ve istatistiksel tabanlı ADA algoritması en uygun kanal setinin belirlenmesinde başarılı sonuçlar vermiştir. Kanal setlerinin belirlenmesinden sonra, Ayrık Dalgacık Dönüşümü (DWT) kullanılarak elde edilen dalgacık katsayıları, sınıflandırmada kullanılacak özelliklerin belirlenmesinde kullanılmıştır. Bu özellikler K en yakın komşu analizi (KNN), Destek Vektör Makinesi (SVM) ve Doğrusal Ayırma Analizi (LDA) sınıflandırma yöntemleri ile farklı özellik küme setleri kullanılarak sınıflandırmaya tabii tutulmuştur. Sınıflandırmada kullanılan özellik setlerinin sınıflandırma başarıları karşılaştırılmıştır. Doğru kanal seti ve

özelliklerin sınıflandırma performansı üzerindeki etkisi incelenmiş, aynı özellik setleri farklı frekans bantlarında test edilmiştir. Sonuç olarak, seçilen kanallar ve özellikler ile %95'lik bir sınıflandırma başarısı elde edilmiştir. Elde edilen sonuç literatürde ilgili veri setiyle elde edilmiş tüm sonuçların üstünde bir sınıflandırma başarısını ortaya koymuştur.

BBA sistemlerinde bir diğer önemli konu istenmeyen kas hareketleri, göz kırpması ve buna benzer olumsuz sinyal etkilerinin veri setinden temizlenmesidir. Çalışmanın ikinci kısmında performansı olumsuz yönde etkileyen göz artefaktlarının tespit edilmesi için FEAD (Fast Eye Artefact Detection) ve ilgili EEG denemelerinden göz artefaktlarının temizlenmesinde kullanılan EBR (Eye Blink Remover) algoritmaları geliştirilmiştir. Algoritmalar MI ve SSVEP tipi EEG sinyallerinin algılanmasına yönelik özgün deneylerle testlere tabi tutulmuş, oldukça başarılı sonuçlar elde edilmiştir. Önerilen sistemde göz artefaktları FEAD algoritmasıyla tespit edilmekte, Independent Component Analysis (ICA) ve DWT tabanlı EBR algoritması ile sinyalin sorunlu kısmı ilgili sinyalden çıkarılmaktadır. EBR algoritması özgün EEG veri setleriyle test edilmiştir. Algoritma genel olarak EEG sinyalini ICA bileşenlerine ayırmakta, literatürden farklı olarak, ilgili sinyalden çıkarılması gereken minimum ICA bileşen sayısını tespit etmekte ve DWT ile sinyale ait sorunlu ICA bileşeninin sadece sorunlu wavelet bileşenlerini elimine ederek, minimum sorunlu sinyali nörolojik sinyalden ayırarak, yüksek oranda gürültü giderilmesini amaçlamaktadır. EBR algoritması, artefakt tespiti, minimum bileşen tespiti ve artefakt özelliklerinin tespiti açılarından özgündür. Göz kırpması içeren EEG sinyal denemelerinin tespitinde, göz kırpmasına özgü frekanslarla filtreleme sonucu elde edilen eşik değeri, zamansal göz kırpma süreleri kullanılırken, silinecek minimum bileşen tespitinde ise, tepe içermeyen sinyal parçalarının temizlik öncesi ve sonrası benzerlikleri temel alınmıştır. Hâlihazırda göz kırpma tepciklerinin başlangıç ve bitiş noktalarının belirlenmesinde kullanılan yaygın bir yöntem yoktur. Çalışmalarımız kapsamında geliştirilen Find Peak Bottom (FPB) algoritması ile göz kırpma tepelerine ilişkin başlangıç ve bitiş noktaları belirlenmektedir. Tümüyle otomatikleştirilmiş bir uygulama olarak geliştirilen EBR sistemi her tip EEG veri setine uygulanabilmektedir. Sisteme girdi olarak verilen EEG veri seti göz kırpmalarından ve benzeri bozucu etkilerden arındırılmış olarak sistem sonucunda

elde edilmektedir. Literatürde, EEG sinyallerinden atrifakt temizleme işlemlerinin başarısının belirlenmesinde, sorunlu sinyalde işlem sonrasında gözlemlenen değişim, işlem öncesi ve sonrasında temizlenen bölge dışındaki sinyal parçasının benzerlik oranı, sorunlu sinyal parçasındaki benzerlik oranı gibi kriterler kullanılmaktadır. Bunların her biri tek başına bir temizlik ölçütü sağlamamakla beraber, birlikte yorumlandığında anlamlı sonuçlar elde edilmektedir. EBR algoritması deneme testleri haricinde üç farklı veri setiyle test edilmiş, sonuç olarak; özgün, gerçek EEG veri setleriyle, %100 artifakt tespiti ve %80,089 işlem sonrası sorunsuz bölge benzerliği ile sinyal temizleme gerçekleştirmiştir.

Bir sistemin performansı sistem hızı yanında sistem doğruluğu, güvenilirliği ve tasarımıyla da doğrudan ilişkilidir. Bu bağlamda tez çalışmasının üçüncü kısmında SSVEP tabanlı bir robot kontrol uygulaması geliştirilmiştir. Uygulamada üçüncü bölümde önerilen FEAD algoritması ile deneğin göz kırpmaya sayıları tespit edilmiş ve bu göz kırpmaya sayıları kullanılarak sistemin aktivasyonu sağlanmıştır. Bu sayede sistemin kontrol edilebilirliği artırılmıştır. Farklı göz kırpmaya sayıları sisteme farklı komutlar olarak atanabilmektedir. Uygulama ile denekler 4 farklı yön komutu ile sadece bilgisayar ekranına bakarak bir robota komut verebilmektedirler. Uygulama performansı farklı sinyal pencere uzunluklarında senkron-asenkron deneylerle Minimum Energy Combination (MEC) ve Canonical Correlation Analysis (CCA) yöntemleri kullanılarak, karşılaştırmalı olarak analiz edilmiştir. Her iki SSVEP tespit yöntemiyle yakın sonuçlar elde edildiyse de, MEC yöntemi kullanıldığında daha başarılı sonuçlar elde edildiği gözlemlenmiştir. Uygulama ile 133,33 bit/dakika bilgi iletim hızı (ITR), 0,9 s sinyal pencere genişliği MEC yöntemi kullanılarak yakalanmıştır. Yakalanan ITR değeri 4 hedefe sahip BBA sistemlerinde oldukça başarılı bir değerdir.

Son olarak tez çalışmasının dördüncü bölümünde yine SSVEP tabanlı 6 sınıftan oluşan bir BBA sistemi önerilmiştir. BBA sistemi sayesinde bilgisayar ekranında bulunan 6 farklı frekansta titreşen kutulardan herhangi birine odaklanılmasıyla istenilen harfler veya semboller bilgisayar ekranına yazdırılabilmektedir. Her bir ikili seçim bilgisayar ekranında bir harf yazımına karşılık gelmektedir. Ekranı bir harf veya sembol yazdırmak için iki seçim işleminin yeterli olması literatürde karşılaşılan

üç veya daha fazla seçimle çalışan BBA speller sistemlerine göre kullanım kolaylığı açısından üstünlük göstermekte ve kullanıcılara daha konforlu bir kullanım sunmaktadır. Önerilen tasarım hem Türkçe hem de Latin harflerini barındırdığından, sistem aracılığı ile hem Türkçe hem de Latince kelimeler yazılabilmektedir. BBA tasarımıyla, yüksek başarıma sahip, kullanıcı dostu bir uygulama amaçlanmıştır. Sistem performansında önemli bir role sahip sinyal pencere uzunluğu üzerinde analizler yapılmıştır. 3 s'lik sinyal pencere genişliği ile hemen hemen tüm deneklerle oldukça yüksek bir sistem doğruluğu elde edilmiş, 77,55 bit/dakikalık ITR değeri 2 s'lik pencere genişliği yakalanmıştır. Uyarı ve sinyal işleminin iki farklı bilgisayar veya kaynağa ayrılmasıyla çok daha iyi sonuçların elde edileceği öngörülmektedir.

Tez çalışması kapsamında elde edilen tecrübeler ışığında, çok kanallı veya yüksek çözünürlüklü BBA sistemlerine yönelik çalışmaların artacağı, deneğe özel kısa eğitimler içeren BBA sistemlerinin gelecek vadettiği öngörülmektedir.

Anahtar Sözcükler : BBA, EEG, ECoG, SSVEP.

Bilim Kodu : 924.1.021

ABSTRACT

Ph. D. Thesis

A STUDY ON PERFORMANCE INCREASING IN PSYCHOPHYSIOLOGICAL MEASUREMENT BASED BRAIN-COMPUTER INTERFACE SYSTEMS

Erdem ERKAN

Karabük University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

Thesis Advisor:

Prof. Dr. Mehmet AKBABA

July 2018, 87 pages

People which are afflicted with neurological conditions or neurodegenerative diseases can't control own muscles by neural pathways. Brain computer interface (BCI) systems offer these people another alternative path for their own neural pathways. This alternative pathway is the direct usage of brain signals by computers without using any vocal muscles by BCIs. A BCI system can be examined in three main sections: acquisition of brain signals, interpretation of signals, and system output. The system output can be device control or words which are on computer screen.

Depending on signal collection method there are different types of brain signals. These types has differences according to the distance of the electrode to the brain tissue. Electroencephalography (EEG), which is obtained via electrodes through the

scalp, is the most commonly used signal type. Electroencephalography (EEG) is another type of brain signal that is acquired invasively by placing electrodes on the brain tissue. Although the EEG signals have higher resolution, the EEG signals have enough resolution for BCI systems. Brain signals have differences for during the movement and preparation of the movement or external sound - visual stimulations. The brain signals are motor imaginary (MI) which related to motion. The brain signals are P300 and SSVEP (Steady State Visual Evoked Potential) related to visual stimuli. EEG and ECoG type brain signals which obtained during the MI and SSVEP based experiments are used in the thesis. MI signals are the type of signal obtained from the motor cortex area of the brain. The SSVEP signals are obtained from the visual cortex of the brain when subjected to a frequency source.

In this thesis study, it is aimed to develop methods for improving the performance of BCI systems. Signal processing algorithms, as well as simple and user-friendly system designs, have an impact on the performance. Therefore, in addition to the signal processing methods, the study is also focused on the new BCI system designs. Firstly, existing methods and datasets in literature related to the topic were analysed in order to gain experience in BCI systems.

In this thesis, four different studies have been carried out to improve the performance in BCI systems. In the first, BCI Competition III dataset 1 consisting of ECoG (Electrocorticography) signals is preferred for learning about BCI systems. In order to decrease the processing load, the number of channels are reduced by eliminating channels (electrodes) which have low separation success. We developed new algorithm ADA (Arc Detection Algorithm) based on visual channel selection to determine quickly the optimal channel subset. Then the Wavelet coefficients were obtained by Discrete Wavelet Transform (DWT) and determined the classification features from Wavelet coefficients. These features are used to classify by KNN (K Nearest Neighbors), SVM (Support Vector Machine) and LDA (Linear Discriminant Analysis) by different feature set combination. The classification successes of feature combinations which are used in classification are compared. The impact on the classification performance of the right channel and the right property choice is observed. Test results are performed with different frequency bands were compared

with the same feature set. As a result, the highest classification accuracy of 95% was obtained by selected channels and feature.

Another important issue in BCI systems is the removal of unwanted muscle movements, eye blinking and other such adverse signal effects from the data set. In the second study, FEAD (Fast Eye Artefact Detection) algorithm and EBR (Eye Blink Remover) algorithms are developed to detecting and removing eye artifacts. Algorithms are tested with experiments to detect motor imaginary (MI) and SSVEP EEG signals, and successful results are obtained. In the proposed system, the eye artifacts are determined by the FEAD algorithm and the problematic part of the signal is extracted from the related signal by ICA (Independent Component Analysis) and DWT (Discrete Wavelet Transform) based EBR algorithm. The EBR algorithm was tested with real EEG data sets. The EBR algorithm divides the EEG signal into ICA components, determines the minimum number of components that must be subtracted from the signal and eliminates only the problematic wavelet components of the ICA components. The EBR algorithm is original for artifact detection, and identification of the ICA subset to be deleted. The system uses threshold value which is filtered with specific frequencies and temporal blinking times for detecting eye blinking. The system also uses correlation coefficient for detecting number of ICA component which will be deleted. Currently there is no common method used to determine the starting and ending points of eye blinking peaks. The FPB (Find Peak Bottom) algorithm is developed within the scope of our studies determines the start and end points of the eye blinking peaks. The fully automated system can be applied to any type of EEG data set. In the literature, the rate of change in the smooth part of the signal and the signal cleanup rate determine the system performance. The EBR algorithm was tested with three different data sets. As a result %100 artifact detection and 80.089 correlation rate was obtained with the original, true EEG data sets.

In the third study a SSVEP based BCI robot control application is introduced and system performance is analyzed for different signal window lengths. At first, the number of eye blinks of the subjects are determined by fast eye artifact detection method (FEAD) which based on visual eye blink detection. These eye blink counts

are used for system activation. System usability is improved by this control. Two consecutive eye blinks which are detected by FEAD method are used for system activation. System deactivation is also provided by the same command. Synchronous and asynchronous experiments are performed on four healthy subjects for performance analyses. EEG data is analyzed in details by asynchronous experiments. During the synchronous experiments, subjects are tried to complete a predefined route which has twelve steps by navigating the robot (Lego Mindstorms EV3). The minimum energy combination (MEC) and canonical correlation analysis (CCA) methods are applied to EEG segments that are different in length in order to detect SSVEPs in both type experiments. ITR values are calculated for different signal window lengths. The results show that the detection accuracy of the MEC method is similar to that of the CCA method, although it is higher than that of the CCA method in situations where the SSVEP has low strength. In synchronous experiments, using MEC method a system peak ITR of 133.33 bit/min is reached for one subject with a 0.9 s signal window length. This ITR value is higher than the previously published studies in the literature for SSVEP based BCI systems.

Finally, a new SSVEP based BCI speller application was introduced and system performance is analyzed for different signal window lengths in experiments. Subject can write Turkish and English letters to computer screen by just using BCI system without using any muscle. The BCI speller has six box which has six letters in each box on the screen. The six letters in the selected box are distributed as one letter each box after the first selection by application. With the second selection, the letter which desired is displayed on the screen. The application contains Latin letters as well as Turkish letters. Experiments are performed on 3 healthy subjects. Subjects try to choose letter by focusing on the boxes which has flickering different frequencies. The minimum energy combination (MEC) method is applied to EEG segments that are having different length in order to detect SSVEPs. The highest ITR value of 77.55 bit/min is obtained for subject 1 with 2 s signal window length. Higher accuracy and more useful a BCI system observed when system signal window length set 3 s.

Experience of the thesis shows that future work on multichannel and high-resolution BBA systems will increase. Also it is concluded that the subject dependent BCI systems including short training will have promising future for obtaining better performance.

Key Word : BCI, EEG, ECoG, SSVEP.

Science Code : 924.1.021



TEŐEKKÜR

Bu tez alıőmasının yrtlmesinde ve oluőumunda ilgi ve desteęini esirgemeyen, engin tecrbelerinden yararlandıęım, ynlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller iőıęında Őekillendiren, en zor zamanımda elimden tutan, sayın hocam Prof. Dr. Mehmet AKBABA'ya, her ihtiya duyduęumda bilgi ve tecrbelerini esirgemedi bu tez alıőmasına yn veren, Northeastern niversitesi Elektrik ve Bilgisayar Mhendislięi ęretim yesi, aynı zamanda biliősel sistemler laboratuvarı (Cognitive Systems Laboratory) direktr Do. Dr. Deniz ERDOęMUŐ'a teőekkrlerimi sunarım.

Deneylerin yapılmasında yardımlarını esirgemeyen, baőta eőim Yasemin ERKAN'a ve Bartın niversitesi Uzaktan Eęitim Uygulama ve Araőtırma Merkezindeki alıőma arkadaőlarıma teőekkr ederim.

Ayrıca sevgili eőim ve ocuklarıma, bana verdikleri manevi desteklerinden tr tm kalbimle teőekkr ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	ix
TEŞEKKÜR.....	xiv
İÇİNDEKİLER	xv
ŞEKİLLER DİZİNİ.....	xviii
ÇİZELGELER DİZİNİ	xx
SİMGELER VE KISALTMALAR DİZİNİ	xxi
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	3
BEYİN BİLGİSAYAR ARAYÜZLERİ.....	3
2.1. BEYİNDEN KASLARA ALTERNATİF İLETİŞİM.....	4
2.2. ELEKTROENSEFALOGRAFİ	5
2.3. BBA TÜRLERİ.....	5
2.3.1. Olay İlişkili Uyarılmış Potansiyeller	6
2.3.2. İstemli Kortikal Potansiyeller	7
2.3.3. Durağan Uyarılmış Potansiyeller.....	8
BÖLÜM 3	10
EKG SİNYAL İŞLEME	10
3.1. SİNYAL İŞLEME VE SINIFLANDIRMA	10
3.1.1. Sinyal İşleme Yöntemleri	10
3.1.2. Sınıflandırma Yöntemleri	11
3.2. TEZ ÇALIŞMASINDA KULLANILAN-ÖNERİLEN YÖNTEMLER	12
3.2.1. Sinyal Önleme.....	12

	<u>Sayfa</u>
3.2.2. Gürültü Tespit-Giderme.....	12
3.2.2.1. FAR Göz Kırpma Tespit Algoritması.....	12
3.2.2.2. Dalgacık Gürültü Giderme.....	14
3.2.2.3. Bağımsız Bileşen Analizi.....	15
3.2.2.4. EBR Algoritması.....	16
3.2.3. Kanal Seçimi.....	21
3.2.3.1. ADA Yay Tespit Algoritması	21
3.2.4. Özellik Çıkarma.....	23
3.2.4.1. Dalgacık Dönüşümü.....	23
3.2.5. Sınıflandırma	24
3.2.5.1. K En Yakın Komşu Analizi	24
3.2.5.2. Destek Vektör Makineleri.....	24
3.2.5.3. Doğrusal Ayırma Analizi.....	25
3.2.5.5. Derin Öğrenme ile EEG Sınıflandırma.....	26
3.2.5.6. MEC Yöntemi	28
3.2.5.7. CCA Yöntemi	30
3.2.5.8. Performans Değerlendirme	31
3.2.5.9. SSVEP Performans Değerlendirme	31
BÖLÜM 4	32
TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR	32
4.1. MOTOR HAREKET HAYALİ ÇALIŞMASI.....	33
4.1.1. Veri Setinin Özellikleri.....	33
4.1.2. Kullanılacak Kanalların Belirlenmesi.....	34
4.1.3. Sinyal Önileme.....	39
4.1.3.1. Filtreleme	39
4.1.3.2. Veri Setinin Standartlaştırılması	40
4.1.4. Özellik Çıkarımı	41
4.1.5. Sınıflandırma	42
4.1.6. Sonuçlar	46
4.1.6.1. KNN, SVM, LDA Sınıflandırma Sonuçları.....	46
4.1.6.2. Derin Öğrenme Ağı Sınıflandırma Sonuçları	50

	<u>Sayfa</u>
4.2. GÖZ ARTİFAKTLARININ TEMİZLENMESİ.....	52
4.2.1. Veri Setinin Özellikleri.....	52
4.2.2. Sinyal Önışleme.....	54
4.2.3. Sinyal Temizleme.....	54
4.2.4. Performans Analizi.....	55
4.2.5. Sonular.....	56
4.3. DURAĐAN GÖRSEL UYARILMIŐ POTANSİYEL ALIŐMASI.....	57
4.3.1. Veri Toplama.....	59
4.3.2. Sinyal Önışleme.....	61
4.3.3. Sinyal İşleme.....	61
4.3.4. Sistem Performansının Deđerlendirilmesi.....	62
4.3.5. Deneysel Sonular ve Deđerlendirme.....	62
4.4. TÜRKE TEMELLİ BEYİN BİLGİSAYAR YAZICISI.....	68
4.4.1. Veri Toplama.....	68
4.4.2. Sinyal Önışleme.....	70
4.4.3. Sinyal İşleme.....	71
4.4.4. Sistem Performansının Deđerlendirilmesi.....	71
4.4.5. Deneysel Sonular ve Deđerlendirme.....	71
BÖLÜM 5.....	75
GENEL SONULAR VE TARTIŐMA.....	75
KAYNAKLAR.....	78
ÖZGEMİŐ.....	87

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. BBA sistemini genel yapısı.....	4
Şekil 2.2. Örnek P300 sinyali.....	6
Şekil 2.3. Farwell ve Donchin tarafından geliştirilen P300 tabanlı BBA sistemi.....	7
Şekil 2.4. Penfield ve Boldrey'in çalışmasında etiketlenmiş motor korteks.....	8
Şekil 3.1. Örnek EEG sinyali ve FAR algoritması özellikleri.....	13
Şekil 3.2. FAR algoritması akış diyagramı.....	14
Şekil 3.3. EBR algoritması akış diyagramı.....	18
Şekil 3.4. FPB algoritması akış diyagramı.....	18
Şekil 3.5. EBR algoritması EEG temizleme ekranı.....	20
Şekil 3.6. ADA algoritması geometrik özellikleri.....	22
Şekil 3.7. ADA algoritması akış diyagramı.....	22
Şekil 3.8. SVM sınıflandırma yapısı.....	25
Şekil 3.9. Derin ağda konvolüsyon.....	27
Şekil 3.10. Derin ağda havuzlama.....	27
Şekil 3.11. Relu ve tanh aktivasyon fonksiyonları.....	28
Şekil 4.1. Tezin genel yapısı.....	32
Şekil 4.2. Zaman domeni 12. kanal ortalaması.....	34
Şekil 4.3. Zaman domeni 38. kanal ortalaması.....	35
Şekil 4.4. 12. Kanal parmak ve dil sınıfı frekans ortalamaları.....	36
Şekil 4.5. 38. Kanal parmak ve dil sınıfı frekans ortalamaları.....	37
Şekil 4.6. BCI competition IV 3. Veri seti kanal 5 ADA sonuçları.....	38
Şekil 4.7. BCI competition IV 3. Veri seti kanal 7 ADA sonuçları.....	38
Şekil 4.8. Filtrelenmiş sinyal 12. kanal frekans domeni.....	39
Şekil 4.9. Eğitim ve test verileri ortalamalarındaki farklılık.....	40
Şekil 4.10. Dalgacık dönüşümü sonuç frekansları.....	41
Şekil 4.11. Dalgacık katsayıları enerji durumu.....	42
Şekil 4.12. KNN ile 12. ve 38. kanal sınıflandırma.....	43
Şekil 4.13. SVM 12. 38. kanallar WC_std ile sınıflandırma.....	44
Şekil 4.14. LDA ile sınıflandırma.....	44
Şekil 4.15. Derin ağ yapısı.....	45

Sayfa

Şekil 4.16. Derin ağ sınıflandırma sonuçları	51
Şekil 4.17. Elektrot yerleşimi	53
Şekil 4.18. EEG kayıt prosedürü	54
Şekil 4.19. Orjinal ve temizlenmiş EEG	56
Şekil 4.20. SSVEP tabanlı sistemin genel yapısı	59
Şekil 4.21. Elektrot yerleşimi	60
Şekil 4.22. BioRadio cihazı	60
Şekil 4.23. Robot Lego EV3	61
Şekil 4.24. SSVEP BBA Sistem arayüzü	61
Şekil 4.25. SSVEP robot sinyal işleme basamakları	62
Şekil 4.26. Pencere genişliklerine göre ITR değerleri.....	65
Şekil 4.27. Ortalama ITR değerleri	65
Şekil 4.28. Türkçe temelli beyin bilgisayar yazıcısı	68
Şekil 4.29. İlk deney örnek bir görüntü.....	68
Şekil 4.30. Türkçe temelli beyin bilgisayar yazıcısı elektrot yerleşimi	69
Şekil 4.31. Beyin bilgisayar yazıcısı sinyal ön işleme adımları.....	70

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 4.1. Derin ağ yapısı	45
Çizelge 4.2. Kanal 12, 38 bir özellik ile sınıflandırma sonuçları.....	47
Çizelge 4.3. Kanal 12, 38 İki özellik sınıflandırma	47
Çizelge 4.4. Kanal 12, 38 Beş özellik ile sınıflandırma.....	48
Çizelge 4.5. Kanal 12, 38 ve 27 tek özellik sınıflandırma	48
Çizelge 4.6. Kanal 12, 38 ve 27 iki özellik sınıflandırma.....	48
Çizelge 4.7. Kanal 12, 38 ve 27 beş özellik sınıflandırma.....	49
Çizelge 4.8. Kanal 12, 38, 21 ve 29 tek özellik sınıflandırma	49
Çizelge 4.9. Kanal 12, 38, 21 ve 29 beş özellik sınıflandırma.....	50
Çizelge 4.10. İterasyon sayısına göre derin ağ ile sınıflandırma sonuçları.....	51
Çizelge 4.11. Elektrot numara ve isimleri.....	54
Çizelge 4.12. EEG veri seti	55
Çizelge 4.13. EBR sonuçları	57
Çizelge 4.14. Asenkron deney sonuçları denek1	63
Çizelge 4.15. Asenkron deney sonuçları denek2	63
Çizelge 4.16. Asenkron deney sonuçları denek3	64
Çizelge 4.17. Asenkron deney sonuçları denek4	64
Çizelge 4.18. Senkron deney CCA sonuçları.....	66
Çizelge 4.19. Senkron deney MEC sonuçları	66
Çizelge 4.20. 5 sn Sinyal pencere genişliği deney sonuçları	71
Çizelge 4.21. 4 sn Sinyal pencere genişliği deney sonuçları	71
Çizelge 4.22. 3 sn Sinyal pencere genişliği deney sonuçları	72
Çizelge 4.23. 2 sn Sinyal pencere genişliği deney sonuçları	73
Çizelge 4.24. SSVEP tabanlı çalışma örnekleri	74

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

μ	: mü
β	: beta
W	: dalgacık katsayıları
μV	: mikrovolt
Hz	: hertz
sgn	: signum
tr	: trace
T	: transpoz
tanh	: hiperbolik tanjant
log	: logaritma

KISALTMALAR

ADA	: Arc Detection Algorithm (Yay Tespit Algoritması)
ALS	: Amyotrophic lateral skleroz (Amyotrofik lateral skleroz)
BBA	: Beyin Bilgisayar Arayüzü
BCI	: Brain computer interface (Beyin Bilgisayar Arayüzü)
BP	: Blood Pressure (Kan Basıncı)
BSS	: Blind Source Separation (Kör Kaynak Ayırma)
CCA	: Canonical Correlation Analysis (Kanonik Korelasyon Analizi)
CSP	: Common Spatial Pattern (Ortak Mekânsal Desen)
DGG	: Dalgacık gürültü giderme
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
EEG	: Electroencephalography (Elektroensefalografi)
EBR	: Eye Blink Remover (Göz Kırpması Temizleyici)
ECOG	: Electrooculography (Elektrokortikografi)
EDA	: Electro Dermal Activity (Elektro Dermal Aktivite)
EMG	: Electromyography (Elektromiyografi)
EOG	: Electrooculography (Elektrooculografi)
ERD	: Event-Related Desynchronization (Olay İlişkili Desenkronizasyon)
ERS	: Event-Related Synchronization (Olay İlişkili Senkronizasyon)
FAR	: Fast Artefact Reject (Hızlı Arifakt Reddi)
FEAD	: Fast Eye Artefact Detection (Hızlı Göz Artefakt Tespiti)
FPB	: Find Peak Bottom (Tepe Dip Bulma)
GA	: Genetik Algoritma
GUI	: Graphical User Interface (Grafiksel Kullanıcı Arabirimi)
ICA	: Independent Component Analysis (Bağımsız Bileşen Analizi)
ITR	: Information Transfer Rate (Bilgi Transfer Hızı)
KNN	: K Nearest Neighbours (K En Yakın Komşu)
LDA	: Linear Discriminant Analysis (Doğrusal Ayırma Analizi)
LFW	: Label Face in Wild (Vahşi Hayatta Etiketli Yüzler)
LIS	: Locked in Syndrome (Kilit Sendromu)
MEC	: Minimum Energy Combination (Minimum Enerji Kombinasyonu)
MEG	: Magnetoencephalography (Manyetoensefalografi)

- MI : Motor Imaginary (Motor Hareket Hayali)
- MPDV : Minimum Peak Distance Value (Minimum Tepe Uzaklık Deęeri)
- MPPV : Minimum Peak Prominence Value (Minimum Tepe ıkma Deęeri)
- MSI : Multivariate Synchronization Index
- P300 : Positive 300 (Pozitif 300)
- SSVEP : Steady State Visual Evoked Potential (Görsel Uyarılmış Duraęan Hal Potansiyeli)
- STD : Standart Sapma Oranı
- SVM : Support Vector Machine (Destek Vektör Makinesi)
- YSA : Yapay Sinir Aęı



BÖLÜM 1

GİRİŞ

Biyomedikal ve makine öğrenme teknolojilerinin gelişmesiyle, insanlardaki psikofizyolojik sinyallerin analiz edilmesi, önemli bir çalışma alanı haline gelmiştir. Araştırmacılar hastalıkları daha doğru teşhis etmek, destek teknolojiler geliştirmek ve insanlığa çok çeşitli alanlarda yardımcı olmak için biyolojik sinyallerini anlamaya ve sınıflandırmaya çalışmaktadır.

Beyin Bilgisayar Arayüzü (BBA) bir iletişim yöntemidir. Ancak bu iletişim yönteminde, beynin gönderdiği iletiler kendi doğal yolu olan sinir sistemi ve kaslar üzerinden geçmez. Bilgisayar ve sinyal yükselteçleri yardımıyla geliştirilen BBA sistemleri, sinir sistemi ve kaslardan oluşan bu yola bir alternatif olarak karşımıza çıkar. BBA'lar, kişilerin kas sistemlerini, bir başka deyişle motor sinir sistemlerini kullanmadan bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını olanaklı hale getirmektedirler. Genel olarak Nörolojik koşullara veya nörodejeneratif hastalıklara maruz kalmış insanlar, Amyotrophic lateral skleroz (ALS) hastaları, Locked in Syndrome (LIS), omurilik yaralanması, inme ve buna benzer rahatsızlıklara sahip insanlar BBA sistemlerinden faydalanmaktadırlar.

Beynimizde gerçekleşen olaylar elektrokimyasal olaylardır. Dolayısıyla bunların hem kimyasal hem de elektriksel boyutu vardır. BBA bu olayların elektriksel kısmı ile ilgilenmektedir. Elektroensefalografi (Electroencephalography, EEG) BBA sistemlerinde kullanılan en yaygın sinyal türüdür. Herhangi bir cerrahi müdahale gerektirmemesi, daha yüksek çözünürlüğe sahip elektrokortikografi (Electrocorticography, ECoG) sinyallerine göre daha kolay elde edilmesi EEG sinyalleriyle yapılan çalışmaların artmasına sebep olmuştur. Bir BBA sisteminde, beyindeki birçok nöronun ateşlenmesiyle ortaya çıkan bu beyin sinyallerinin algılanabilir ve yorumlanabilir olması gerekmektedir.

Günümüzde arařtırmacılar tarafından popüler bir saha olan BBA çalıřmaları her geen gün geliřmektedir. BBA sistemleri hasta destek sistemlerinden de öte askeri sahalara tařınmaktadır. Tüm geliřmelerine ragmen kullanıcı dostu, kolay eriřilebilir BBA sistemlerinin sayısı oldukça azdır.

Bu çalıřmanın amacı, biyomedikal alanında büyük bir öneme sahip BBA sistemlerini arařtırmak, ilgili sistemlere örnek, kullanıcı dostu uygulamalar geliřtirmek ve bu uygulamaların performansına katkı sađlayacak yöntemler önermektir.

Hazırlanan bu tez çalıřması, genel itibarıyla literatür taraması ve deneysel çalıřmalar olmak üzere iki kısımdan oluřmaktadır. Literatür taraması ve deneysel çalıřmalar kendi içinde alt bařlıklardan oluřmaktadır. Bunlardan birinci bölüm “Giriř” olup burada çalıřmanın kısa özeti verilmiřtir. İkinci ve üçüncü bölümde, sırasıyla bu çalıřmanın temelini oluřturan BBA sistemleri ve bu sistemlerde kullanılan ve geliřtirilen sinyal iřleme-sınıflandırma yöntemleri bir literatür taramasıyla anlatılmıřtır. Dördüncü bölümde bu tez kapsamında hazırlanan dört farklı BBA çalıřması, yapılan deneyler detaylı bir biçimde tanıtılmıřtır. Deneysel çalıřmaların öncesinde Karabük Üniversitesi, Tıp Fakültesi, Giriřimsel Olmayan Klinik Arařtırmalar Etik Kurulundan kurul raporu alınmıřtır.

Beřinci bölümde, bir önceki bölümde dört ana bařlık altında verilen BBA uygulamalarına yönelik genel sonuçlar ve deđerlendirmelere yer verilmiř, çalıřmalarımızın geldiđi noktadan sonra gelecekte yapılması düşünölen çalıřmalar hakkında, deđerlendirmeler yapılmıřtır.

BÖLÜM 2

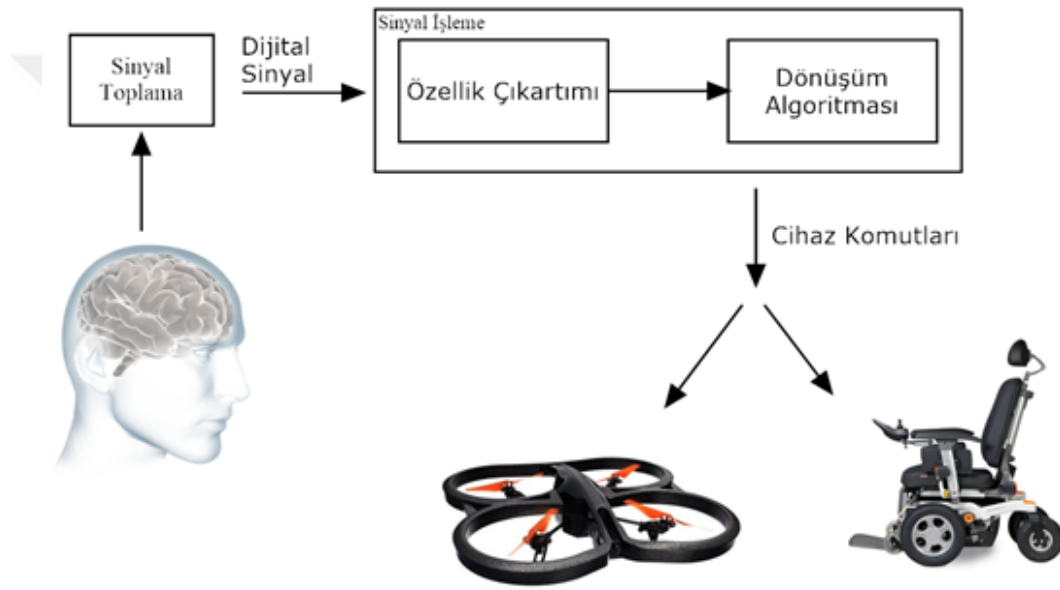
BEYİN BİLGİSAYAR ARAYÜZLERİ

Günümüzde, biyomedikal ve makine öğrenme teknolojilerinin hızla gelişmesiyle, biyolojik sinyallerin araştırılması popüler bir çalışma alanı olmuştur. BBA her ne kadar popüler bir çalışma alanı olsa da, yüksek maliyetli sinyal yükselteçleri, zorlu sinyal toplama süreçleri, denek bulma zorlukları gibi nedenler bu alandaki çalışmaları olumsuz yönde etkilemektedir. Araştırmacılar hastalıkları daha doğru teşhis etmek, destek teknolojiler geliştirmek ve insanlığa çok çeşitli alanlarda yardımcı olmak için biyolojik sinyalleri anlamaya ve sınıflandırmaya çalışmaktadır. Bu sinyallerin en yaygın kullanılanları; EEG, ECoG, Electro Dermal Activity (EDA), Blood Pressure (BP), Electromyography (EMG), Electrooculography (EOG) dir. EEG BBA sistemlerinde kullanılan en yaygın sinyal türüdür. Bu psikofizyolojik sinyallerin beyin ile ilgili olanları, beyin içindeki birçok nöronun ateşlenmesiyle oluşur. Ancak elde edilmiş yöntemleri farklıdır. Örnek olarak aynı nöronsal etki ile oluşan bu sinyallerden EEG sinyallerinin elde edilmesi daha kolay ve güvenli iken, çözünürlüğü daha yüksek olan ECoG sinyallerinin elde edilmesi yapılan cerrahi müdahaleden ötürü daha riskli ve zordur.

BBA çalışmaları ilk olarak 1970'lerde Vidal ile başlamıştır [1, 2]. Bu ilk çalışmadan yaklaşık 40 yıl sonra insan kafa derisinden EEG ölçümü Berger tarafından gerçekleştirilmiştir [3]. BBA sinyal yükselteçlerinin ve bilgisayarların gelişimiyle, yaklaşık 20 yıl sonra, araştırmacıların ilgisini daha fazla çekmeye başlamış ve bu alandaki çalışmalar hızla artmıştır. EEGLAB ve BCI200 gibi BBA sinyal işleme kütüphanelerinin araştırmacıların kullanımına sunulmasıyla bu alandaki çalışmalar artan bir ivme kazanmıştır [4, 5, 6].

2.1. BEYİNDEN KASLARA ALTERNATİF İLETİŞİM

Nörolojik koşullara veya nörodejeneratif hastalıklara maruz kalmış insanlar nöral yollarla kendi kaslarını kontrol edemezler. ALS, LIS, omurilik yaralanması, inme ve buna benzer rahatsızlıklar kasları kontrol eden sinir yollarını etkiler. BBA bu insanlara kendi sinir yollarından farklı alternatif bir yol sunmaktadır [7, 8]. Genel bir BBA sisteminin yapısı Şekil 2.1 ile verilmiştir.



Şekil 2.1. BBA sisteminin genel yapısı [3].

Bu alternative yol, kimi zaman bir elektrikli sandalyeyi hareket ettirmeye yardımcı olurken, kimi zaman da konuşamayan bir hastanın bilgisayar ekranına dökülen sözcükler olarak karşımıza çıkmaktadır. BBA'lar iletişim için bilgisayar faresi, kontrol kolu, göz takibiyle çalışan sistemler gibi, yardımcı teknoloji sistemleridir [9, 10].

Bir BBA sistemi beş bileşen etrafında değerlendirilebilmektedir [11].

1. Sinyal türü (ECoG, EEG, vb olabilir)
2. Sinyal işleme (sinyalin belirlenmesi, sınıflandırma)

3. Kullanıcı arayüzü (Grafical User Interface "GUI")
4. Sistem çıktısı (Konuşma, metin veya cihaz yönlendirme)
5. Sistemin kazancının değerlendirilmesi

BBA çalışmaları genel olarak bu 5 bileşen etrafında, engelli bireylerin hayat standartını kolaylaştıracak, kullanıcı dostu, hızlı ve güvenilir BBA sistemleri tasarlamayı hedefler [12].

2.2. ELEKTROENSEFALOGRAFİ

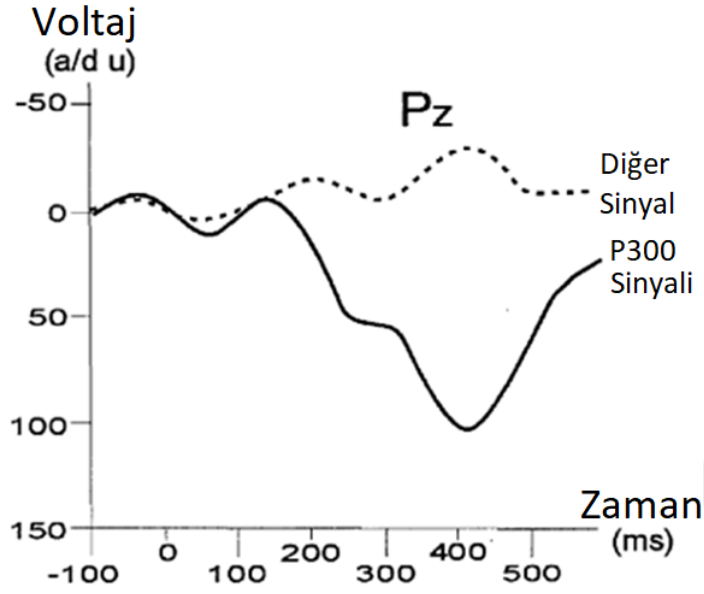
Beyin içindeki birçok nöronun ateşlenmesiyle ortaya çıkan beyin sinyallerinden en yaygın kullanılan türü olan elektroensefalografi kısaca EEG olarak adlandırılmaktadır. EEG düşük genlikli voltaj değerleridir. Genellikle μV seviyelerinde gerçekleşir. Düşük sinyal gürültü oranına sahiptir. Ancak EcoG sinyalleri invazif, yani cerrahi müdahale ile elde edilirken, EEG sinyalleri daha güvenli bir şekilde kafa derisi üzerinden elektrotlar aracılığıyla elde edilir [8]. BBA sistemlerinin temel girdisi olan EEG sinyallerinin sürekli, kesintisiz, büyük boyutta olması, kişilere göre farklılıklar göstermesi, sinyallerin sahip olduğu düşük sinyal gürültü oranı, bu sinyallerin işlenmesindeki zorluklar olarak karşımıza çıkmaktadır. Bu bağlamda BBA sistemlerinin doğruluğu artarken, sinyal işleme zamanının azalarak daha etkin olması, kullanıcı dostu, pratik sistemlerin geliştirilmesi sağlanmalıdır.

2.3. BBA TÜRLERİ

BBA'lar genel olarak bağımlı ve bağımsız olma üzere ikiye ayrılır. Bağımlı BBA'da uygulanan kişinin maruz kaldığı bir etkiye karşılık sinyal üretmesi beklenirken, bağımsız BBA'da kişinin sadece bir şeyi yapmak istemesi beklenir. Örnek olarak; bağımlı BBA'da matris formundaki verilen harflerden vurgulanan kısımdaki ilgili harfe odaklanılması istenirken, bağımsız BBA'da sadece bir harfin düşünülmesi istenmektedir. BBA sistemleri her ne kadar bağımlı ve bağımsız olarak iki kısımda incelense de sistemin kullandığı sinyal türüne göre de farklı şekillerde sınıflandırılabilirler.

2.3.1. Olay İlişkili Uyarılmış Potansiyeller

Olay ilişkili uyarılmış potansiyel tabanlı BBA sistemlerine, rutin ve sürekli uyarılarla birlikte verilen başka bir uyarana maruz kalan kullanıcıdan, uyarılmadan yaklaşık 300 ms sonrasında elde edilen özel bir sinyal tespit edilmeye çalışılır. 300 ms ile 500 ms arası negatif yönlü gözlemlenen bu sinyale P300 sinyali adı verilir [13, 14, 15]. Şekil 2.2 de örnek bir P300 sinyali verilmiştir [16].



Şekil 2.2. Örnek P300 sinyali [16].

Bu sinyalden dolayı olay ilişkili potansiyel tabanlı BBA sistemleri P300 tabanlı BBA sistemleri olarak da adlandırılabilir. P300 sinyali sayesinde kullanıcıların amacı, hangi uyarana odaklandıkları tespit edilebilir. Tespitin yapılabilmesi için görsel veya işitsel uyarılar kullanılmaktadır. Farwell ve Donchin P300 sinyalini temel alan ilk öncü BBA sistemini tasarlamışlardır. Sistem sayesinde kullanıcıya 6x6 matris formunda bir ekranla sunulan harf ve rakamlardan oluşan yapı aracılığı ile kullanıcının odaklandığı sembol (matris elemanı) BBA ile tespit edilmiştir. Matrise ait bir satır veya bir sütunun parlaklığı 125 ms de bir vurgulanarak rutin uyarma işlemi gerçekleştirilmiş, kullanıcının seçtiği karakteri içeren satır veya sütun her yandığında kullanıcının sayma işlemi yapmasıyla da P300 sinyali oluşumu sağlanmıştır. Beynin perietal bölgesinden alınan bu EEG sinyallerinin ortalaması ile

de kullanıcın seçtiği sembol sistem tarafından tespit edilebilmiştir [17]. Şekil 2.3 de geliştirilen BBA sisteminin 6x6 matris formundaki ekran görüntüsü verilmiştir.


Choose one letter or command					
A	G	M	S	Y	*
B	H	N	T	Z	*
C	I	O	U	*	TALK
D	J	P	V	FLN	SPAC
E	K	Q	W	*	BKSP
F	L	R	X	SPL	QUIT

Şekil 2.3. Farwell ve Donchin tarafından geliştirilen P300 tabanlı BBA sistemi [17].

P300 tabanlı BBA sistemleri kullanıcı eğitimine ihtiyaç duymamasına karşın, birçok seçim denemesinin ortalamasının alınmasını temel almakta, bu da işlem süresini uzatmaktadır. Akram ve arkadaşları, 2014 yılında yaptıkları çalışmada, P300 tabanlı karakter yazıcıların hızını artırma amaçlı, kendi sözlüğü olan ve yazılacak kelimeyi önceden tahmin etme kabiliyetine sahip bir BBA sistemi geliştirmişlerdir. Yaptıkları testlerde kelime başına 1.91 dakika ortalama zaman hesaplamışlardır [18].

2.3.2. İstemli Kortikal Potansiyeller

Hareketin hayal edilmesiyle ile tetiklenen kortikal bölgedeki voltaj senkronizasyonu veya desenkronizasyonu sonucu elde edilen ölçümlerdir. Kullanıcı eğitimlerinin ön planda olduğu, eğitimler ile sistem performanslarının artırılabilirdiği BBA türüdür [19]. Motor Hareket hayali, Frontal, Parietal, Oksipital ve Temporal olarak dört ana bölümde incelenen beynin ilgili bölgesindeki sinyal değişimi olarak gözlemlenir. Penfield ve Boldrey 1937 yılında yaptıkları çalışmada, bir ameliyat esnasında beynin seçilen bölgelerine uyarımlar göndererek, insan vücudundaki bazı kas gruplarını Frontal bölgedeki kas gruplarıyla eşleştirmişlerdir [20]. Şekil 2.4 ile bu eşleştirme ile elde edilen sonuçlar verilmiştir.



Şekil 2.4. Penfield ve Boldrey'in çalışmasında etiketlenmiş motor korteks [20].

Uyanık insanlarda, duygusal girdilere maruz kalınmaz ve motor hareketleri üretilmezken, 8-12 Hz aralığında EEG sinyali gözlenmektedir [21]. Bu boş durumda elde edilen sinyallere μ (mü) ritmi adı verilmektedir. 18-26 Hz arasında olanlara β (beta) ritmi adı verilmektedir. Hareket veya harekete hazırlık evrelerinde mü ve beta ritimlerinde azalma gözlemlenmektedir. Bu azalma, Olay İlişkili Desenkronizasyon (Event-Related Desynchronization, ERD) olarak adlandırılmaktadır. Bunun tersi olan mü ve beta ritimlerindeki artış ise hareket sonrası relaks durumlarında gözlemlenmektedir. Bu durum ise; Olay İlişkili Senkronizasyon (Event-Related Synchronization, ERS) olarak tanımlanmaktadır [22, 23]. Bununla beraber, ERD ve ERS sinyalleri gerçek hareketlerin yanında, bu hareketlerin hayal edilmesinde de gözlemlenmektedir [24]. İstemli kortikal potansiyel tabanlı BBA sistemleri uzun kullanıcı eğitimi gerektirirler [25, 26, 27].

2.3.3. Durağan Uyarılmış Potansiyeller

İşitsel veya görsel uyarılara odaklanmak beynin işitsel ve görsel korteks bölgelerinde ilgili frekanslarda voltaj salınımlarına yol açmaktadır. Bu yolla deneğin

hangi uyarana odaklandığı analiz edilebilmektedir. Durağan uyarılmış potansiyel tabanlı BBA sistemleri farklı frekanslarda yanıp sönen ışıklara veya işitsel uyarılara cevap üretmek için tasarlanmış sistemlerdir. İşitsel uyarı kullanılan BBA sistemleri konusunda son yıllarda bazı çalışmalar yapılmıştır. Sistem işitsel uyarımı sağlayan hoparlör veya kulaklıklarla desteklenmekte kullanıcının hangi uyarana odaklandığı tespit edilmeye çalışılmaktadır [28]. İşitsel uyarı kullanan BBA sistemleri daha çok görmek bozukluğuna sahip kullanıcılara yönelik hazırlanmaktadır. Genel olarak bu alandaki çalışmalar daha çok görsel uyarı tabanlı BBA sistemlerine yönelmiştir. Görsel uyarılmış tabanlı BBA sistemlerinde de, farklı frekanslarda, yanıp sönen ışık vb. etkilere maruz bırakılan kullanıcının, bu etkilerden herhangi birine odaklanması ile elde edilen EEG sinyalleri kullanılır. Bu BBA sistemleri, bilgi transfer hızlarının yüksek olması, az sayıda EEG kanalı (elektrot) kullanılması, kullanıcı eğitimine ihtiyaç duymaması ve daha az zamanlama hassasiyetine ihtiyaç duyması üzerinde fazlaca çalışılan ve uygulama geliştirilen BBA alanıdır [29, 30, 31]. Matris formundaki bir klavye düzeninde her bir sembolü farklı frekansta titreştiren görsel uyarılmış potansiyel tabanlı birçok BBA sistemi geliştirilmiştir [32, 33]. Calhoun ve arkadaşları görsel uyarılmış potansiyel tabanlı, ortalama karar süresi 2,1 sn olan ve %92 doğrulukla çalışabilen bir uçuş simülatörü geliştirmişlerdir [34]. Gernot ve arkadaşları geliştirdikleri sistemiyle bir protez kolu dört farklı yönde hareket ettirmeyi başarmışlardır [30]. Hwang ve arkadaşları her bir sembolü 5-10 Hz arasında 0,1 Hz frekans farkı ile titreşen 30 sembolden oluşan özel bir LED tasarımına sahip BBA sistemi geliştirmişlerdir [35]. Yin ve arkadaşları 36 sembolden oluşan görsel uyarılmış potansiyel tabanlı BBA sistemi geliştirmişlerdir [36]. Volosyak ve arkadaşları Bremen BCI olarak duyurdukları sistemle 4 farklı yön oku kutucuyla kullanıcıya yönlendirme imkânı sağlamış, 5. kutucuyla da üzerinde bulunduğu sembolü seçebilmesini sağlamışlardır [37, 38, 39, 40].

BÖLÜM 3

EEG SİNYAL İŞLEME

Genel olarak, bir BBA'nın amacı beyin aktivitelerini bilgisayarların anlayacağı komutlara dönüştürmektir. Bunu yapmak için; regresyon ve sınıflandırma algoritmaları kullanılabilir [41, 42]. Sınıflandırma algoritmalarının kullanılması en yaygın kullanılan yaklaşımdır. Sınıflandırma algoritmaları, beyin aktivitelerinin örüntülerinin tanımlanmasında kullanılmaktadır [43]. Bir yüzün tanınması, herhangi bir kelimenin anlaşılması, cebimizdeki bir anahtarın seçilmesi gibi olayların hepsinin temelinde örüntü tanıma yatmaktadır. Dolayısıyla bir BBA sistemi de beyin arzuladığı obje veya eylemlere aracılık ettiği için bir çeşit örüntü tanıma sistemi olarak tanımlanabilmektedir [44]. Sistemin performansı; sinyalin seçilen özellikleri ve bu özelliklerin kullanıldığı sınıflandırma yönteminin performansı ile doğrudan ilişkilidir. Özellik çıkarımı ve sınıflandırma bir BBA sisteminin omurgasını oluşturmaktadır. EEG sinyalleri kullanılan BBA sistemlerinde, sinyalin genliği, bant gücü, güç spektral yoğunluğu, otomatik geri besleme parametreleri, uyarlamalı geri besleme parametreleri, zaman ve frekans gibi özellikleri sınıflandırmada kullanılmaktadır [43]. Bu bölümde BBA sistemlerinin bel kemiğini oluşturan sinyal işlemeyle ilgili genel bir literatür bilgisi, beraberinde uygulamada kullandığımız yöntemlere ilişkin daha detaylı bilgilere yer verilmiştir. Bu yöntemlerle beraber kullanılacak ve bu yöntemlere destek mahiyetindeki geliştirdiğimiz yardımcı destek yöntemleri de bir sonraki bölümde verilecektir.

3.1. SİNYAL İŞLEME VE SINIFLANDIRMA

3.1.1. Sinyal İşleme Yöntemleri

EEG sinyalleri gürültü barındıran, düşük sinyal gürültü oranına sahip dolayısıyla çevresel etkilerden ve artefaktlardan kolay etkilenen fizyolojik sinyallerdir. Sinyale

uygulanan sinyal işleme basamaklarıyla bu etkiler en aza indirilerek sinyalin sınıflandırmasında kullanılacak en iyi sinyal özellikleri belirlenir. P300 uyarılmış tabanlı BBA sistemlerinde P300 sinyali, Motor Hareket Hayali tabanlı BBA sistemlerinde μ (Mü) ritimleri, Durağan Uyarılmış Potansiyel tabanlı BBA sistemlerinde oktilal bölge frekansları ağırlıklı olarak sınıflandırma özelliklerinin belirlenmesinde tercih edilir. Genel olarak tüm BBA sistemlerinde ilk sinyal işleme basamağı, istenmeyen frekans aralıklarının elimine edilmesi için yapılan filtrelemedir. Yine ağırlıklı olarak bu adımda, istenen frekans aralıklarının elde edilmesi için tasarlanmış band geçiren filtreler kullanılır. Bu adım sonrasında kanal (elektrot) ve her bir kanala ait örnekleme frekansına bağlı sinyalden oluşan veriyi içeren çok boyutlu bir EEG verisi elde edilmiş olur. Bu noktadan sonra elde edilen bu çok boyutlu EEG verisinden sınıflandırma özelliklerini elde etme amaçlı sinyal boyutunun azaltılması, gürültü giderilmesi, artifakt elimine etme amaçlı birçok yöntem kullanılmaktadır. Sinyal ortalamalarının alınması [45, 46, 47], altörnekleme [45, 48, 49, 50], ayırık ve sürekli dalgacık dönüşümü [45, 51, 52], LDA [53], kanal seçimi [49, 50, 51, 53, 54], Bağımsız Bileşen Analizi (ICA) [55, 56, 58], Temel Bileşen Analizi [58, 59] ilgili yöntemlerden en yaygın kullanılanlarıdır.

3.1.1. Sınıflandırma Yöntemleri

Sınıflandırıcı, Olay İlişkili Uyarılmış Potansiyel tabanlı BBA sistemlerinde P300 gibi belirgin bir sinyali tespit etmeye çalışırken, Durağan Durum Uyarılmış Potansiyel tabanlı BBA sistemlerinde kullanıcının hangi uyarımı takip ettiğini, İstemli Kortikal Potansiyel tabanlı BBA sistemlerinde ise bir resmin, bir metnin veya sözcük gurubunun neden olduğu beyin ritmini tespit etmeye çalışır. Yaygın kullanılan sınıflandırma yöntemlerine örnek olarak LDA [45, 48, 51, 60, 61], SVM [49, 50, 53, 61, 62], Yapay Sinir Ağları (YSA) [63, 64], Genetik Algoritma (GA) [65] verilebilir.

3.2. TEZ ÇALIŞMASINDA KULLANILAN-ÖNERİLEN YÖNTEMLER

3.2.1. Sinyal Önışleme


Tez kapsamında yapılan çalışmalarda sinyal standartizasyonu, filtreleme gibi sinyal önışleme işlemleri yapılmıştır. Bu işlemlerle sınıflandırmada kullanılacak EEG sinyallerinin sinyal gürültü oranının artırılması amaçlanmıştır.

3.2.2. Gürültü Tespit-Giderme

Analiz edilecek psikofizyoljik sinyallerde istenmeyen kas hareketleri, göz kırpması vb. sebeplerden kaynaklanan sinyal gürültüsü gözlenebilmektedir. Bu noktada istenmeyen gürültü kaynağı ve gürültü sinyalinin özelliklerinin iyi bilinmesi gerekir. Çünkü sinyalden çıkarılacak gürültü bileşenin özellikleri, sinyalin temizlenmesinde kullanılır. Bu bağlamda, çalışmalar kapsamında, istenmeyen sinyal bileşenlerini tespit ve temizleme için algoritmalar geliştirilmiştir.

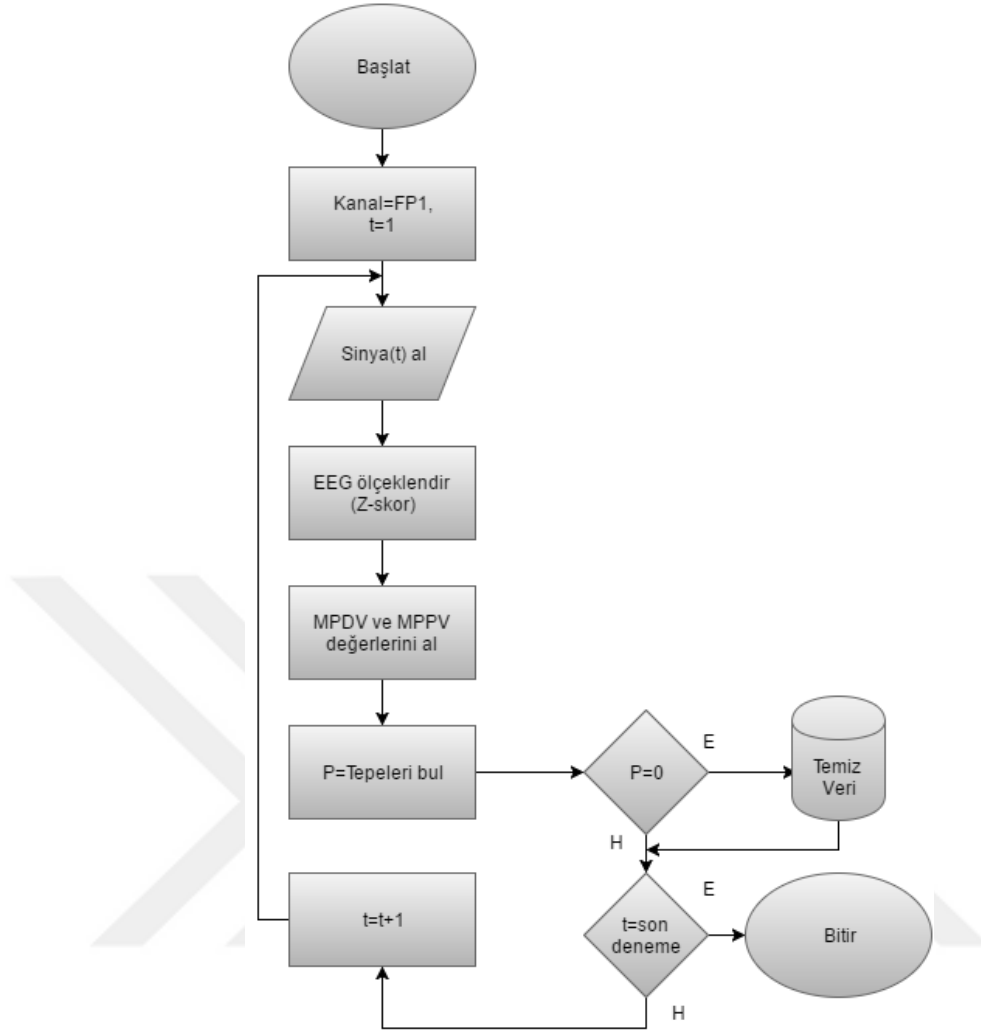
3.2.2.1. FAR Göz Kırpma Tespit Algoritması

Sinyalden gürültü temizlenmesinin ilk basamağı gürültünün tanınması ve tespit edilmesidir. Bu işlemi hızlı bir şekilde yapmak için FAR (Fast Artefact Reject) yöntemi geliştirilmiştir. FAR ile istatistiksel olarak belirlenen sinyal tepeciklerine ait MPPV (Minimum Peak Prominence Value) ve MPDV (Minimum Peak Distance Value) gibi geometrik özelliklere göre hareket ve göz kırpması gibi belirgin artifakt içeren denemeleri kolayca tespit edebilmektedir. Yapılan çalışmalarda MPPV ve MPDV değerleri sırasıyla 0,3 s ve $1,3e-04$ seçilmiştir. Şekil 3.1 ile ilgili FAR özellikleri örnek bir EEG sinyali üzerinde gösterilmiştir. Burada MPPV tepe çukuru yüksekliğini temsil ederken, MPDV ise iki tepe arasındaki en küçük zaman farkını temsil eder. Seçilen 0,3 s lik MPDV yapılan deneyler sonucunda normal aralıklarla göz kırpan 4 farklı deneğe göre belirlenmiştir.



Şekil 3.1. Örnek EEG sinyali ve FAR algoritması özellikleri.

FAR algoritmasına ait akış diyagramı ise Şekil 3.2 ile verilmiştir.



Şekil 3.2. FAR algoritması akış diyagramı.

3.2.2.2. Dalgacık Gürültü Giderme

Sinyali zaman ölçek alanında incelenmesine olanak sağlayan Wavelet Transform (WT), günümüzde sinyal işleme alanında yaygın bir şekilde kullanılmaktadır. Sinyal gürültü giderme veya gürültü bastırma da bunlardan biridir. Dalgacık Gürültü Giderme (DGG), W ve W^{-1} sırasıyla ileri ve geri yönlü dalgacık dönüşümünü ifade etmek üzere;

$$W_i = W(x_i) \quad (3.1)$$

$$\widehat{W}_i = T(W_i, \lambda) \quad (3.2)$$

$$\widehat{C}_i = W^{-1}(\widehat{W}_i) \quad (3.3)$$

W dalgacık katsayıları, $T(\lambda)$ treshold operatör, \hat{W} tresholding sonrası dalgacık katsayıları ve \hat{C} gürültü giderme işlemi sonrası elde edilen sinyali temsil etmek üzere Denklem 3.3 şeklinde ifade edilebilir [66].

3.2.2.3. Bağımsız Bileşen Analizi (ICA)

Kör Kaynak Ayırma (BSS, Blind Source Separation) problemi, BBA artefakt gidermede, sinyal ayrımı dâhil olmak üzere çeşitli mühendislik uygulamalarında kullanılmaktadır. ICA, BSS problemini çözen istatistiksel ve yüksek hesaplama karmaşıklığına sahip bir tekniktir. Bu hesaplama yöntemi, bir dizi doğrusal, karışık, çok değişkenli sinyalin birbirinden ayrılması ve bu bileşenlerin kendi aralarında bağımsız, yaklaşık orijinal sinyalleri oluşturan bir sinyal grubuna dönüştürülmesi için kullanılır [67, 68]. ICA'nın özü istatistiksel bağımsızlığa dayanır. ICA Gaussian olmayan tahminlere göre entropi ölçümlerini ve korelasyon matrislerini kullanır. Klasik ICA modeli aşağıdaki ifadeyle tanımlanır:

$$x(t) = As(t) \quad (3.4)$$

Denklem 3.4 ile verilen ifade de $x(t)$ alınan sinyal vektörünü, A karıştırma matrisini ve $s(t)$ bağımsız kaynakları ifade eder.

Çoğu ICA algoritması karıştırma matrisinin tersi W matrisini hesaplamaya odaklanır.

$$Wx(t) = y(t) \quad (3.5)$$

$y(t)$ yaklaşık olarak orijinal sinyalleri ifade eder. Yani $y(t) \approx s(t)$ dir. Çalışmalarda daha çok gerçek zamanlı uygulamalarda kullanılan, paralel uygulamalara da uyarlanabilen, FastICA algoritması tercih edilmiştir [69, 70]. Bağımsız bileşen yaklaşımları için Kurtosis metodunu kullanır.

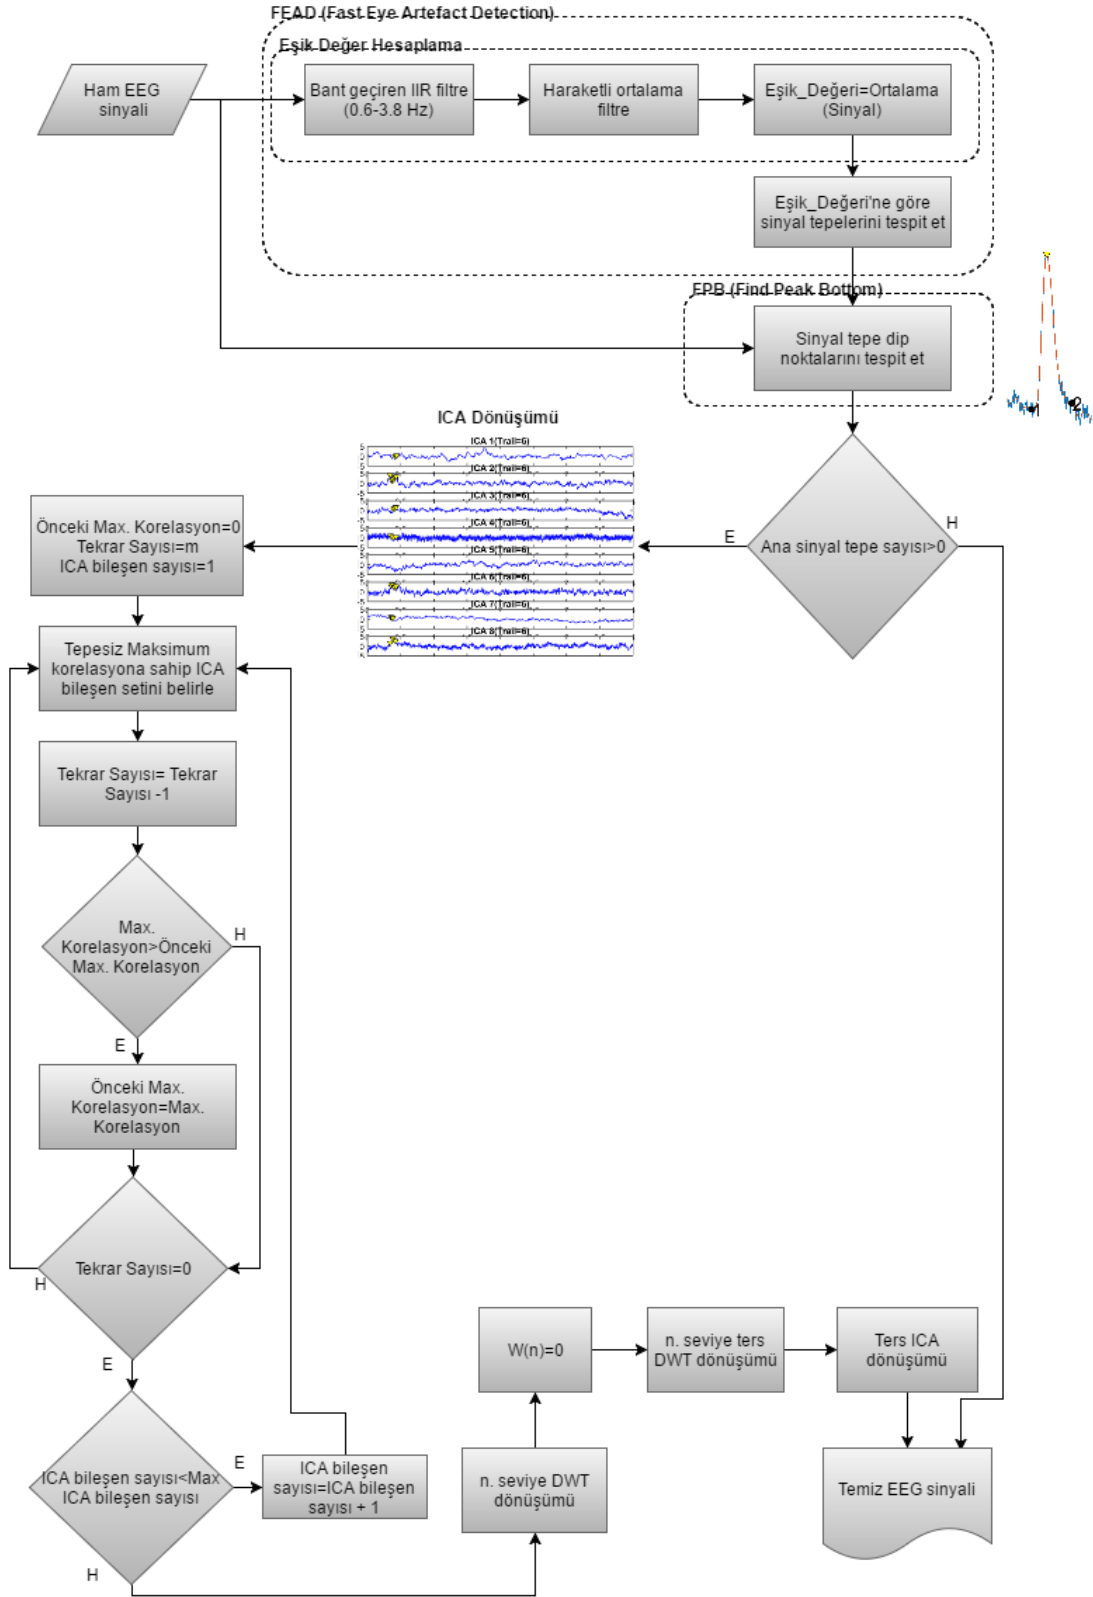
Aşağıda FastICA işlem basamakları verilmiştir;

1. Rastgele W_i belirle
2. $W_i^+ = E(\phi(W_i^T X)) W_i - E(\phi(W_i^T X))$
3. $W_i = \frac{W_i^+}{\|W_i^+\|}$
4. $i = 1$ için 7. basamağa git, değilse 5. basamaktan devam et
5. $W_i^+ = W_i - \sum_{j=1}^{i-1} W_i^T W_j W_j$
6. $W_i = \frac{W_i^+}{\|W_i^+\|}$
7. Yakınsama yoksa 2. Basamağa git, değilse tüm bileşenler çıkarılıncaya kadar $i = i + 1$ yap 1. basamağa git

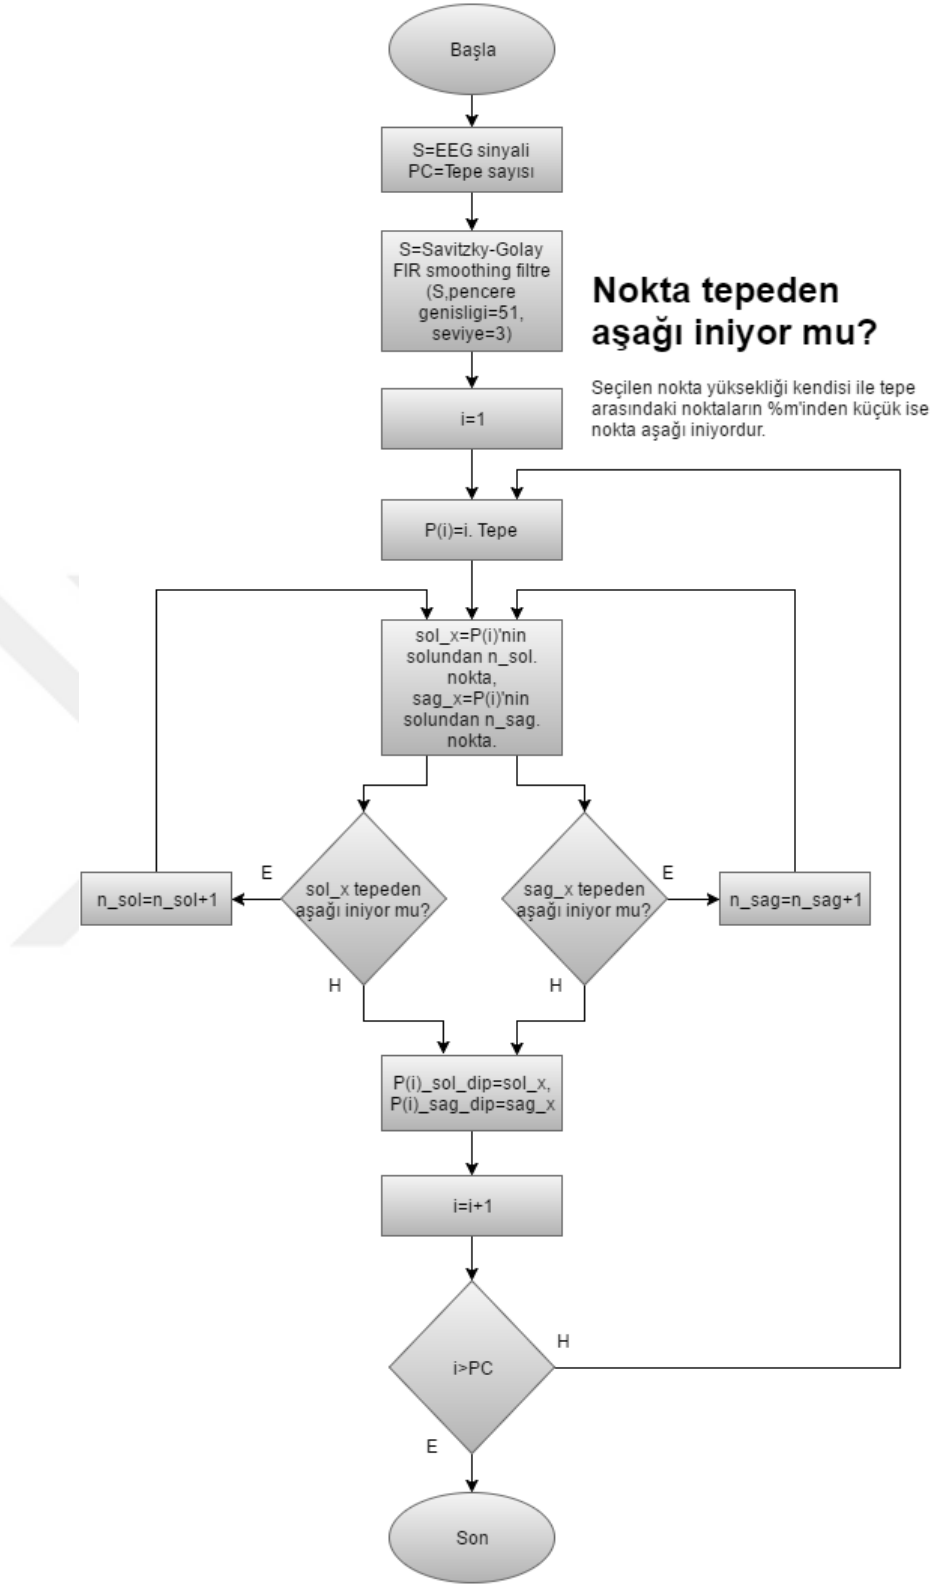
3.2.2.4. EBR Algoritması

EBR (Eye Blink Remover) algoritması FAR algoritmasının yine tez kapsamında geliştirilmiş sürümü olan FEAD (Fast Eye Artefact Detection) algoritması ile beraber çalışarak, veri seti içerisinde göz kırpması içeren denemeleri tespit edip, ilgili deneme sinyalinden göz kırpmasını temizlemektedir. Algoritmalar MI ve SSVEP tabanlı EEG sinyallerinin algılanmasına yönelik özgün deneylerle testlere tabii tutulup, başarı sonuçlar elde edilmiştir. Önerilen sistemde göz artefaktları FEAD algoritmasıyla tespit edilmekte, ICA ve DWT tabanlı EBR algoritması ile sinyalin sorunlu kısmı, ilgili sinyalden ayıklamaktadır. Herhangi bir sinyalin ICA bileşenlerine ayrılmasına SOBI, JADE, FASTICA gibi yöntemler kullanılmaktadır. EBR algoritması ICA bileşenlerini ayrılmasında FASTICA yöntemini kullanmaktadır. FASTICA yönteminin paralel programlamaya uygunluğu düşünüldüğünde, bu doğrultuda algoritma performansının artırılması amaçlanmaktadır. EBR algoritması üretilmiş sinyalden ziyade gerçek EEG veri setleriyle test edilmiştir. Algoritma EEG sinyalini ICA bileşenlerine ayırmakta, literatürden farklı olarak, ilgili sinyalden çıkarılması gereken minimum bileşen sayısını tespit etmekte ve DWT ile sinyale ait sorunlu ICA bileşenlerinin, sadece sorunlu wavelet bileşenlerini elimine etmektedir. Böylece gürültü içeren sinyalin az bir kısmı sinyaleden çıkarılmakta ve nörolojik bilgi korunmaktadır. EBR algoritması, artefakt tespiti, minimum bileşen tespiti ve artefakt özelliklerinin tespiti açılarından özgündür. Göz kırpması içeren EEG sinyali tespitinde göz kırpmasına özgü

frekanslarla filtrelenen eşik değeri, zamansal göz kırpma süreleri kullanılırken, silinecek minimum bileşen tespiti tepe içermeyen sinyal parçalarının temizlik öncesi ve sonrası benzerlikleri temel alınarak belirlenmektedir. Hâlihazırda göz kırpma tepciklerinin başlangıç ve bitiş noktalarının belirlenmesinde kullanılan yaygın bir yöntem yoktur. Çalışmalarımız kapsamında geliştirilen FPB (Find Peak Bottom) algoritması ile göz kırpma tepelerine ilişkin başlangıç ve bitiş noktaları belirlenmektedir. Tümüyle otomatikleştirilmiş bir uygulama olarak geliştirilen sistem her tip EEG veri setine uygulanabilmektedir. Sisteme girdi olarak verilen EEG veri seti göz kırpmalarından ve benzeri bozucu etkilerden arındırılmış olarak sistem sonucunda çıktı olarak alınmaktadır. Literatürde EEG sinyal temizleme çalışmalarında, işlemin başarısı, sorunlu sinyalde, işlem sonrasında gözlemlenen değişim, işlem öncesi ve sonrasında temizlenen bölge dışındaki sinyal parçasının benzerlik oranı, sorunlu sinyal parçasındaki benzerlik oranı gibi kriterler kullanılarak değerlendirilmektedir. Bunların her biri tek başına bir temizlik ölçütü olmamakla beraber birlikte yorumlandığında anlamlı sonuçlar elde edilmektedir. EBR algoritması deneme testleri haricinde üç farklı veri setiyle tam olarak test edilmiş, sonuç olarak; özgün, gerçek EEG veri setleriyle, %100 artifakt tespiti ve %80,089 işlem sonrası sorunsuz bölge benzerliği ile sinyal temizleme gerçekleştirmiştir. EBR ve FBT algoritmalarına ait akış diyagramları sırasıyla Şekil 3.3 ve Şekil 3.4 de verilmiştir.

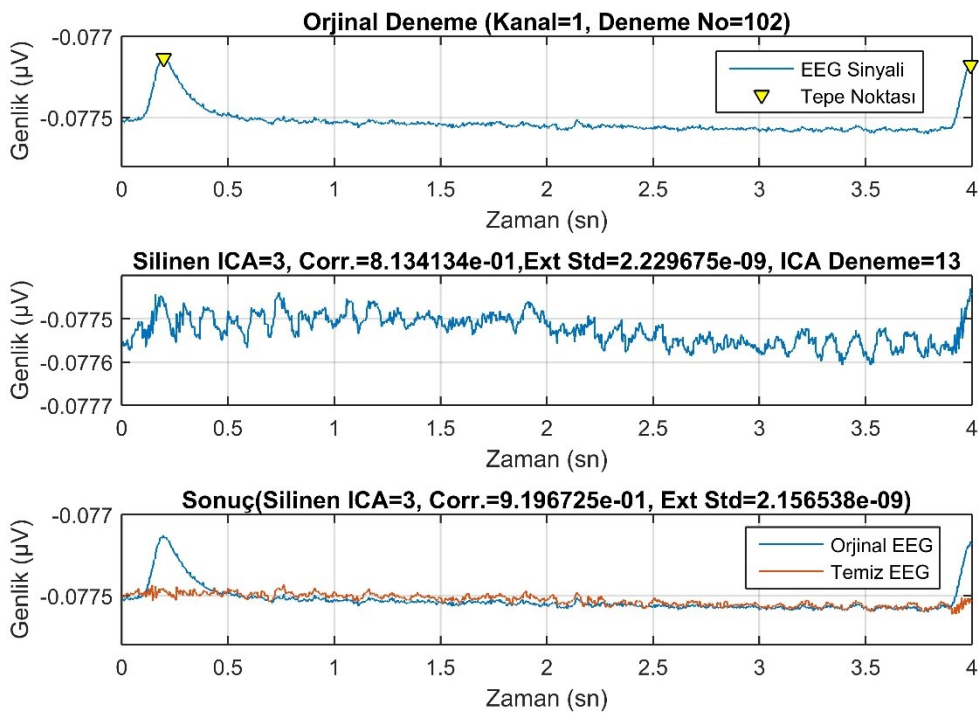


Şekil 3.3. EBR algoritması akış diyagramı.



Şekil 3.4. FPB algoritması akış diyagramı.

EBR gözartifaktı temizleme uygulamasına ait örnek bir EEG sinyali Şekil 3.5 ile verilmiştir. Şekil 3.5 de sırasıyla uygulama tarafından tespit edilen göz kırpmaları, temizleme sırasındaki deneme ve temizlenmiş EEG sinyalinin son hali görülmektedir. Şekil 3.5 den de anlaşılacağı üzere sistem tarafından 1. kanal'a ait 102. denemede iki adet göz kırpması tespit edilmiş, 3 adet ICA bileşenine ait dalgacık sinyallerinde yapılan bastırmalar ile yaklaşık %92 korelasyona sahip temiz EEG sinyali elde edilmiştir.



Şekil 3.5. EBR algoritması EEG temizleme ekranı.

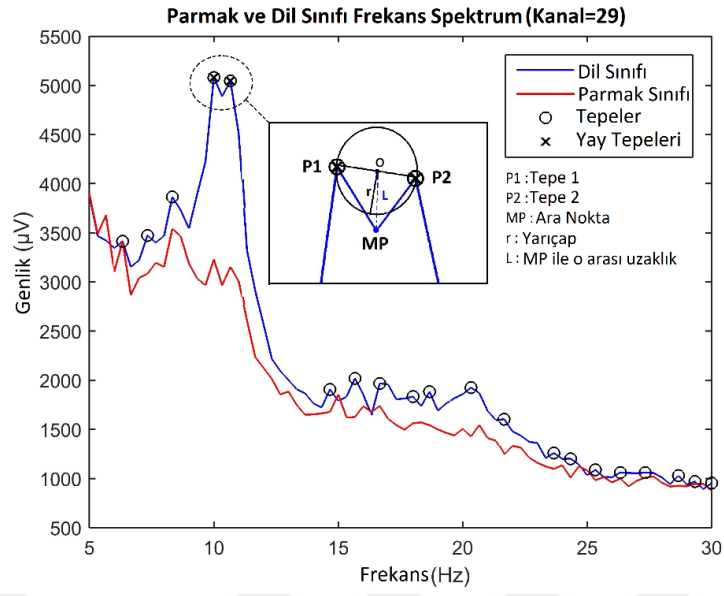
FPB algoritması ile belirlenen sinyal tepesinden, tepenin sağ ve solundan olmak üzere aşağı doğru inilerek ilgili tepenin bitiş noktaları yani tepe dip noktaları belirlenmektedir. Dip noktalarının belirlenmesinde sağdan ve soldan seçilen noktalara ait yükseklik, tepe noktası yüksekliği ile karşılaştırılmakta ve tepe ile karşılaştırılan noktaların tepeden aşağı inme oranı hesaplanarak, tepenin sağ ve solundaki dip noktalar belirlenmektedir.

3.2.3. Kanal Seçimi

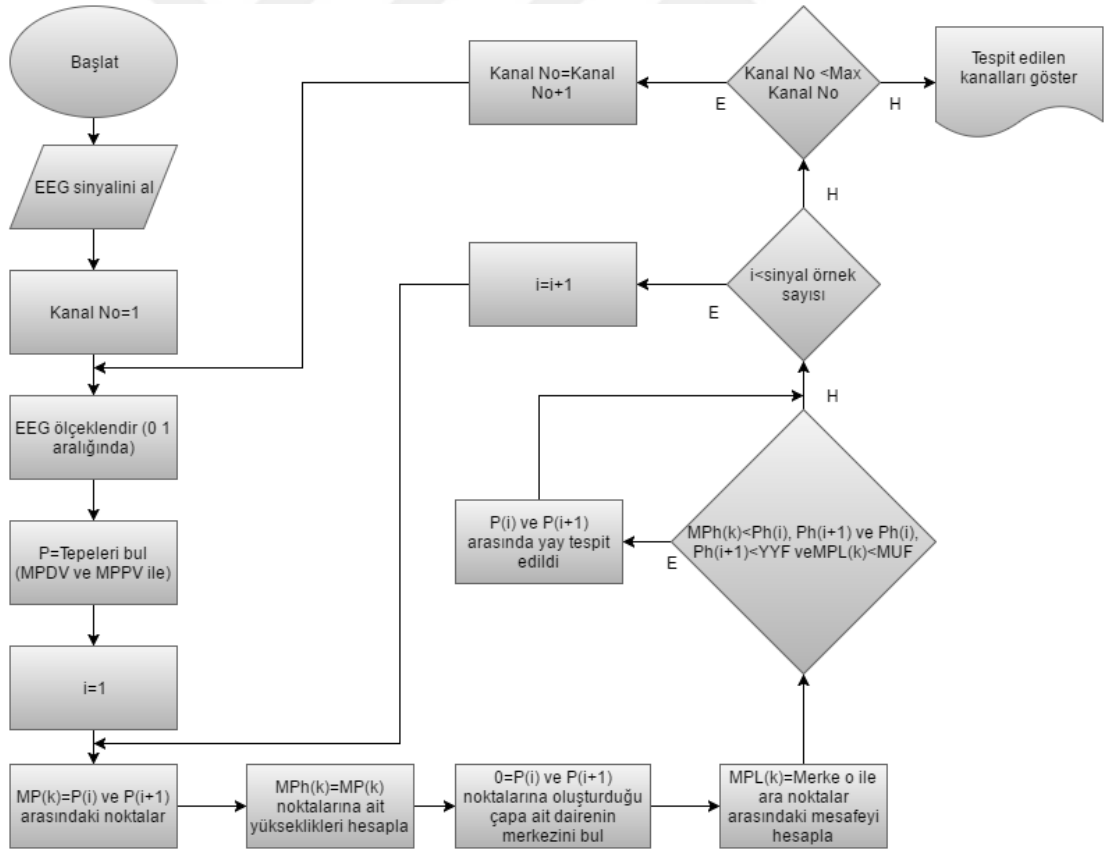
BBA sistemlerinde kanal, sınıflandırmada kullanılacak sinyalleri toplayan elektrotlara karşılık gelmektedir. Bu elektrotların her biri aynı seviyede ayırıcı özellik barındıran bilgi içermemekte, ayırt edici özellikler barındıran kanalların öne çıkarılması gerekmektedir. Kanal seçiminde CSP (Common Spatial Pattern) algoritması, görsel kanal seçimi vb. gibi yöntemlerin yanında tüm kanalların zaman ve frekans spektrumu ortalama değerlerine bakılarak öznetelik çıkarmada kullanılacak kanallar tespit edilebilir [71].

3.2.3.1. ADA Yay Tespit Algoritması

Kanal sayısının fazla olduğu BBA sistemlerinde her bir kanalın görsel olarak tek tek incelenmesi ve uygun olan kanalların göz yordamıyla tespit edilmesi bizi bu işin daha hızlı ve kolayca yapılabilirliğini araştırmaya yönlendirmiştir. Bu noktada kanal seçimini hızlandırmak ve daha etkin bir hale getirmek için ADA (Arc Detection Algorithm) geliştirilmiştir. Motor hayal hareketleri frekans spektrumunda 10 Hz civarlarında yay veya taç benzeri bir şekil oluşturabilir [21]. ADA algoritması frekans spektrumunda 10 Hz frekans bölgesi yakınlarında, bu yay veya taç benzeri yapıya özgün matematiksel ve istatistiksel özelliklerden yola çıkılarak geliştirilmiştir. Algoritma sayesinde, daha önce görsel olarak tespit edilen sınıflandırma kanalları çok daha hızlı bir şekilde tespit edilebilmiştir. Şekil 3.6 ve 3.7 ile sırasıyla algoritmada kullanılan geometrik özellikler ve ADA algoritması akış diyagramı verilmiştir.



Şekil 3.6. ADA algoritması geometrik özellikleri.



Şekil 3.7. ADA algoritması akış diyagramı.

ADA algoritması ile öncelikle ilgili sinyale ait belli bir frekans aralığındaki tepe noktaları tespit edilmekte, her iki tepe noktası ve bu tepe noktalarını üzerinde bulunduran çembere ait geometrik özellikler hesaplanmaktadır. İstatiksel olarak bu çember merkezine belli bir uzaklık bandında bulunan iki tepe arası noktaların, yay oluşturup oluşturmadığı belirlenmektedir.

3.2.4. Özellik Çıkarma

EEG sinyallerine ait minimum, maksimum, ortalama, standart sapma, güç yoğunluğu gibi değerler sınıflandırma özellikleri, sinyal öznitelikleri olarak kullanıldığı gibi, ilgili sinyale ilişkin Dalgacık dönüşümü katsayıları da başlıbaşına sinyal özneliği olarak belirlenebilir.

3.2.4.1. Dalgacık Dönüşümü

Dalgacık dönüşümü (WT) sinyal işlemede fazlaca kullanılan, sinyalin zaman ve frekans bilgisinin aynı anda korunduğu matematiksel bir yöntemdir. WT seçilen ana dalgacığa göre, sinyali bu ana dalgacığın farklı ölçek ve konumdaki bileşenleri şeklinde ifade eder. Ψ Dönüşümde kullanılan ana dalgacığı temsil etmek üzere, WT katsayıları Denklem 3.6 de formüle edilmiştir.

$$WTC(\text{Ölçek}, \text{konum}) = \int_{-\infty}^{+\infty} x(t)\Psi(\text{ölçek}, \text{konum}, t)dt \quad (3.6)$$

WT'de ölçeklendirme 2 ve 2'nin katları şeklinde seçilirse hem hızlı hem de en az sürekli WT kadar iyi sonuç vermektedir. Bu WT formuna da Ayrık Dalgacık Dönüşümü (DWT) denilmektedir. DWT eşitliği Denklem 3.7 ile verilmiştir [45, 51, 52].

$$DDK(j, k) = \sum_j \sum_k x(k)2^{-\frac{j}{2}}\Psi(2^{-j}n - k) \quad (3.7)$$

3.2.5. Sınıflandırma

Sınıflandırma iki veya daha fazla sınıfın, tespit edilen sınıf özniteliklerine göre birbirlerinden sistem tarafından ayrılması olarak tanımlanabilir. Yapılan çalışmalar kapsamında literatürde kullanılan farklı sınıflandırma yöntemleri kullanılmıştır.

3.2.5.1. K En Yakın Komşu Analizi

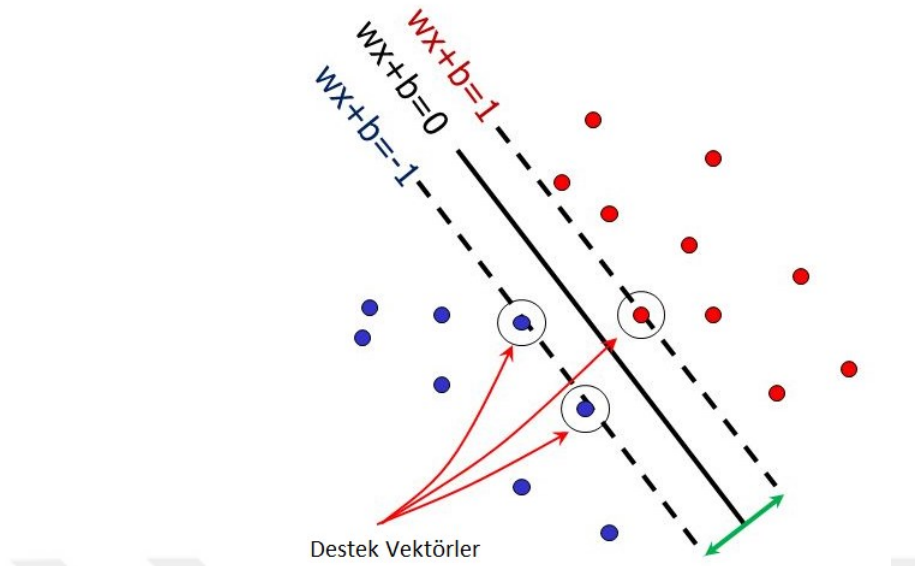
K en Yakın Komşu (KNN) sinyal işleme alanında en yaygın olarak kullanılan sınıflandırma algoritmasıdır. Bilinmeyen bir test vektörü, eğitim kümesinde kendisine en yakın k adet komşusunun etiketi ile etiketlenilerek sınıflandırma işlemi yapılır. Kompleks birçok sınıflandırma metoduna göre iyi sonuçlar vermektedir.

3.2.5.2. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri, başta örüntü tanıma olmak üzere, çok geniş bir kullanım alanı olan popüler bir sınıflandırma algoritmasıdır [72, 73]. $x_i \in R^d$ Sınıflandırılması istenen uzayın özelliklerini, $y_i \in \{-1, +1\}$ de o özelliğe ait sınıf etiketini ve d boyutu temsil etmek üzere Denklem 3.8 sınıflandırılacak uzayı ifade etmektedir.

$$(x_1, y_1), (x_2, y_2), \dots (x_m, y_m) \quad (3.8)$$

Eğer iki sınıfın $w * x + b = 0$ şeklinde bir hiper düzlemlerle ayrıldığını düşünürsek; problem en uygun w ve b değerleriyle, her iki sınıf arasındaki uzaklığı maksimum yapan hiper düzlemin bulunmasıdır. İki sınıflı bir yapıda belirtilen hiper düzlem, örnek bir sınıflandırma ve destek vektörleri Şekil 3.8 ile gösterilmiştir. Denklem 3.9 uygun w ve b değerleriyle elde edilen fonksiyonun z denemesinin hangi sınıfı temsil ettiğini belirlemektedir [74].



Şekil 3.8. SVM sınıflandırma yapısı.

$$f(z) = \text{sgn}((\hat{w}, z) + \hat{b}) \quad (3.9)$$

3.2.5.3. Doğrusal Ayırma Analizi

Doğrusal Ayırma Analizi (LDA) ile öncelikle sınıflandırılması istenen gruplar için ayırıcı fonksiyonlar ve bu fonksiyonlar için ayırma en fazla etkisi olan değişkenler belirlenir. Bu değişkenlere ayırıcı (discriminate) değişkenler denir. LDA, sınıflandırma ve boyut indirgemedede kullanılmaktadır. LDA, S_W ve S_B sırasıyla sınıf içi ve sınıflar arası dağılım matrislerini temsil etmek üzere; ayırım vektörü W eşitlik 3.10 de verilen Fisher oranına göre iki sınıfı birbirinden ayırır [75].

$$J(W) = \text{tr}\left(\frac{W^T S_B W}{W^T S_W W}\right) \quad (3.10)$$

$$S_B = (\mu_i - \mu_j)(\mu_i - \mu_j)^T \quad (3.11)$$

$$S_W = P_i \Sigma_i + P_j \Sigma_j = \Sigma_{ij} \quad (3.12)$$

T transpozu, $tr(\cdot)$ trace, W_i ve W_j farklı iki sınıfı, μ_i ve μ_j sınıf ortalamalarını, Σ_i ve Σ_j kovaryans matrisleri, P_i ve P_j sınıflara ait öncelikli olasılığı temsil etmektedir. Sınıflar arası dağılım matrisleri Eşitlik 3.11 ve 3.12 ile verilmiştir.

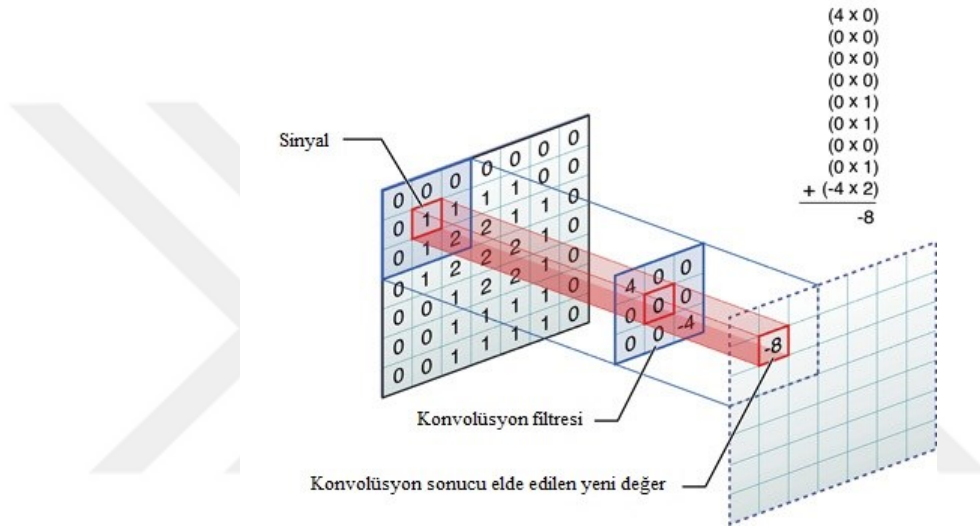
Optimal ayırma vektörü W ise eşitlik 3.13 ile verilmiştir [75].

$$\begin{aligned} W &= S_W^{-1}(\mu_i - \mu_j) = (P_i \Sigma_i + P_j \Sigma_j)^{-1}(\mu_i - \mu_j) \\ &= \Sigma_{ij}^{-1}(\mu_i - \mu_j) \end{aligned} \quad (3.13)$$

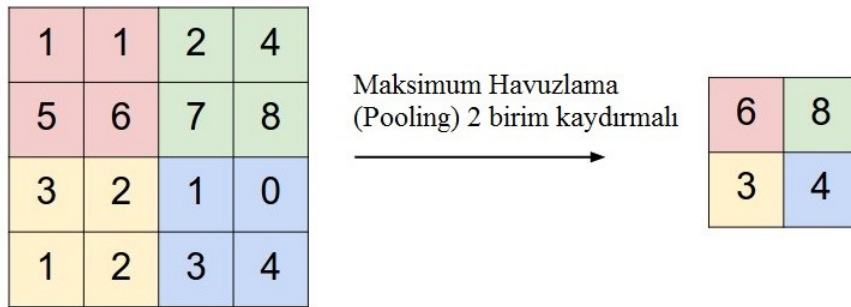
3.2.5.4. Derin Öğrenme ile EEG Sınıflandırma

Yapay sinir ağları (YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı elemanlardan oluşan, her bir elemanın kendine ait bir hafızası olan, eğitim örnekleriyle öğrenebilen, sonrasında da daha önce karşılaşmadığı örnekler hakkında karar verebilen yazılımsal yapılardır. YSA'lar ağırlıklı olarak görüntü tanıma, ses tanıma gibi alanlarda kullanılmaktadır. Popülarlığı her geçen gün artan derin öğrenme, makine öğrenme yöntemlerinden YSA'ları temel alan bir yöntemdir. Google, Facebook, Microsoft gibi firmalar bu makine öğrenme yöntemi üzerinde yoğun çalışmalar yürütmektedir [76, 77, 78]. Günümüzde, derin öğrenme, YSA'lar gibi başta görüntü tanıma olmak üzere video analizi, konuşma tanıma vb. alanlarda başarıyı yüksek bir yöntem olarak karşımıza çıkmaktadır. Örnek olarak; yüz tanıma alanında denektaş testi olarak bilinen LFW (Label Face in Wild) veri kümesi ile oluşturulan yüz tanıma ağı insan başarısının üstüne çıkmayı başarmıştır. İnsanın bu veri kümesindeki başarısı, %97.53 iken Google araştırma grubunun 2015 yılındaki yayınında, yüz tanıma başarısı %99.63 olarak raporlanmıştır [79, 80]. Geleneksel öğrenme yöntemlerinde matematiksel temelli yöntemlerle elde edilen öznelik vektörleri, yine bilinen sınıflandırma yöntemleriyle sınıflandırmaya tabi tutulurken, derin öğrenme ile önceden belirlenmiş bir matematiksel modele ihtiyaç duyulmamaktadır. Uygun öznelikler sisteme girilen veri setinden otomatik olarak öğrenilmektedir. Derin öğrenme yöntemlerinin bir diğer avantajı ise, genelleştirilebilir olmasıdır. Bir probleme yönelik tasarlanan derin öğrenme ağı, başka bir problem üzerinde de kullanılabilir. En büyük dezavantajı ise, çok fazla sayıda eğitim verisine ihtiyaç duymasındır. Konvolüsyon, havuzlama (pooling),


softmax katmanları, bir derin ağın temel katmanlarıdır. Konvolüsyon ve havuzlama işlemleri sırasıyla Şekil 3.9 ve Şekil 3.10 ile verilmiştir. Aktivasyon fonksiyonları ile doğrusallık giderilen derin ağlarda konvolüsyon ve havuzlama filtreleriyle boyutlar bir nevi şifreli olarak azaltılmaktadır. Popüler olarak kullanılan aktivasyon fonksiyonları sigmoid veya hiperbolik tanjant aktivasyon fonksiyonlarıdır. Relu (rectified linear unit) ve tanh aktivasyon fonksiyonlarının karşılaştırması Şekil 3.11 ile verilmiştir. Sigmoid fonksiyonu ise tanh fonksiyonunun ölçeklendirilmiş ve kaydırılmış halidir [81].



Şekil 3.9. Derin ağda konvolüsyon.



Şekil 3.10. Derin ağda havuzlama.



Şekil 3.11. Relu ve tanh aktivasyon fonksiyonları [81].

Relu fonksiyonu Denklem 4.10 ile verildiği gibi ilgili değerler arasında aldığı en yüksek değeri döndürür [81].

3.2.5.5. MEC Yöntemi

Minimum Enerji Kombinasyonu (MEC) yöntemi genel olarak üç adımdan oluşmaktadır [82, 83];

Bu üç adım:

1. İlk olarak kaydedilen sinyalden, ilgilenilen frekans bileşenleri ve harmonikleri tümüyle çıkarılır. Kalan sinyal tamamıyla ilgi duyulmayan gürültü bileşenlerinin oluşturduğu sinyaldir.
2. Elde edilen sinyali bastıracak doğrusal bir matris elde edilir.
3. Gürültü bileşenlerini en iyi şekilde bastıracak doğrusal matris, ilk sinyalimize uygulanır.

Elektrot i deki voltaj değeri; i elektrot numarası, t zamanı, f uyartım frekansını ve N_h harmonik sayısını temsil etmek üzere denklem 3.14 deki şekliyle verilebilir.

$$y_i(t) = \sum_{k=1}^{N_h} (a_{i,k} \sin 2\pi kft + b_{i,k} \cos 2\pi kft) + E_{i,t} \quad (3.14)$$

Burada sinyal iki kısımdan oluşmaktadır. İlk kısım sinyalin kendisi ve harmoniklerini içeren sinus ve cosinüs bileşenleri diğer kısım da gürültü ve arzu edilmeyen kısımları

ifade etmektedir. $a_{i,k}$ ve $b_{i,k}$ sinus ve cosinüs bileşenlerinin genliklerini ifade etmektedir. Elektrot i ye ait voltaj g_i sinus ve cosinüs genlikleri olan $a_{i,k}$ ve $b_{i,k}$ yı temsil etmek üzere denklem 3.15 şeklinde genelleştirilebilir.

$$y_i = Xg_i + E_i \quad (3.15)$$

Y ölçülen sinyalizim olmak üzere, öncelikle ilgi duyulan tüm frekanslar ölçülen sinyalden çıkarılmalıdır. Bunun için denklem 3.16 kullanılır. Denklem 3.16 sonunda elde edilen sinyal sinyalizimin istenmeyen kısmıdır.

$$\hat{Y} = Y - (X^T X)^{-1} X^T Y \quad (3.16)$$

\hat{Y} Matrisine ait öz vektörlerin öz değerlerine oranı olan W matrisinin en küçük değeri \hat{Y} matrisini minimum yapar. Bu istenmeyen kısmın minimum olmasıdır. W matrisi denklem 3.17 ile verilmiştir.

$$W = \left[\frac{v_1}{\sqrt{\lambda_1}} \dots \frac{v_{N_s}}{\sqrt{\lambda_{N_s}}} \right] \quad (3.17)$$

Aynı zamanda kanal vektörü S tüm kanallardan alınan sinyal Y ile \hat{Y} matrisini minimum yapan W ile denklem 3.18 daki gibi çarparsak gürültüyü minimum yapmış oluruz.

$$S = YW \quad (3.18)$$

İlgili frekansa ait güç, N_s kanal sayısı ve N_h harmonik sayısı olmak üzere değeri denklem 3.19 daki gibi hesaplanabilir.

$$\hat{P} = \frac{1}{N_s N_h} \sum_{l=1}^{N_s} \sum_{k=1}^{N_h} \|X_k^T S_l\|^2 \quad (3.19)$$

Denklem 3.20 de verilen maksimum güç değerine sahip olan frekans, aranan frekans değeridir.

$$f_{result} = \operatorname{argmax}(\hat{P}_i) \quad (3.20)$$

3.2.5.6. CCA Yöntemi

Kanonik korelasyon analizi (CCA) iki veri seti arasındaki korelasyonu temel alan çok değişkenli istatistiksel bir yöntemdir [84]. Eğer bu iki veri seti $X \in R^{I_1 \times J}$ ve $Y \in R^{I_2 \times J}$ ve bu veri setlerinin doğrusal kombinasyonları sırasıyla $\tilde{x} = W^T X$ ve $\tilde{y} = V^T Y$ ise, CCA Denklem 3.21 ile verilen optimizasyon problemini çözerek, \tilde{x} ve \tilde{y} arasındaki korelasyonu maksimize etmek için $W \in R^{I_1 \times J}$ ve $V \in R^{I_2 \times J}$ şeklinde bir çift doğrusal dönüşüm matrisi elde etmeye çalışır.

$$p = \max(W, V) \frac{E[\tilde{x}\tilde{y}]}{\sqrt{E[\tilde{x}^2]E[\tilde{y}^2]}} = \frac{W^T X Y^T V}{W^T X X^T W V^T Y Y^T V} \quad (3.21)$$

En yüksek p değeri \tilde{x} ve \tilde{y} arasındaki maksimum korelasyona denk gelir. Denklem 3.22 deki $M = (f_1, f_2, f_3, \dots, f_m)$ değerleri, hedefler için uyartım frekanslarını, X I_1 kanalından elde edilen EEG sinyalini, Y_m de sinus ve cosinüs ile üretilen referans sinyallerini temsil etmektedir. Ayrıca m uyartım sinyal indeksini, H sinyal harmonik sayısını, f_s örnekleme frekansını ve J örnek sayısını ifade eder.

$$Y_m = \begin{pmatrix} \sin(2\pi f_m \frac{1}{f_s}) & \dots & \sin(2\pi f_m \frac{1}{f_s}) \\ \cos(2\pi f_m \frac{1}{f_s}) & \dots & \cos(2\pi f_m \frac{1}{f_s}) \\ \vdots & \vdots & \vdots \\ \sin(2\pi H f_m \frac{1}{f_s}) & \dots & \sin(2\pi H f_m \frac{1}{f_s}) \\ \cos(2\pi H f_m \frac{1}{f_s}) & \dots & \cos(2\pi H f_m \frac{1}{f_s}) \end{pmatrix} \quad (3.22)$$

Denklem 3.22 deki her bir Y_m referans sinyali için p değeri hesaplanır. En yüksek p değeri X sinyali ile en fazla korelasyona sahip referans sinyalidir. Bu referans sinyali, aynı zamanda SSVEP tabanlı BBA sistemlerinde odaklanılan hedefi temsil etmektedir.

3.2.5.7. Performans Deęerlendirme

Bir sistemin performansı hız, doęruluk, güvenilirlik gibi faktörlerle ölçülür. Bunun yanında kullanım kolaylığı, tasarım gibi faktörler de sistem performansına etki eden faktörlerdir.

3.2.5.8. SSVEP Performans Deęerlendirme

SSVEP sistemlerde, genel olarak sistem performansı, dakikada iletilen bit sayısı ile ölçülmektedir. T işlem süresini, C_n sınıflandırma sayısını, B_t her bir denemedeki bit sayısını, N hedef sayısını, p de sınıflandırma başarısını temsil etmek üzere bilgi transfer hızı (ITR) denklem 4.20 ve 4.21 aracılığıyla hesaplanabilir [83, 85].

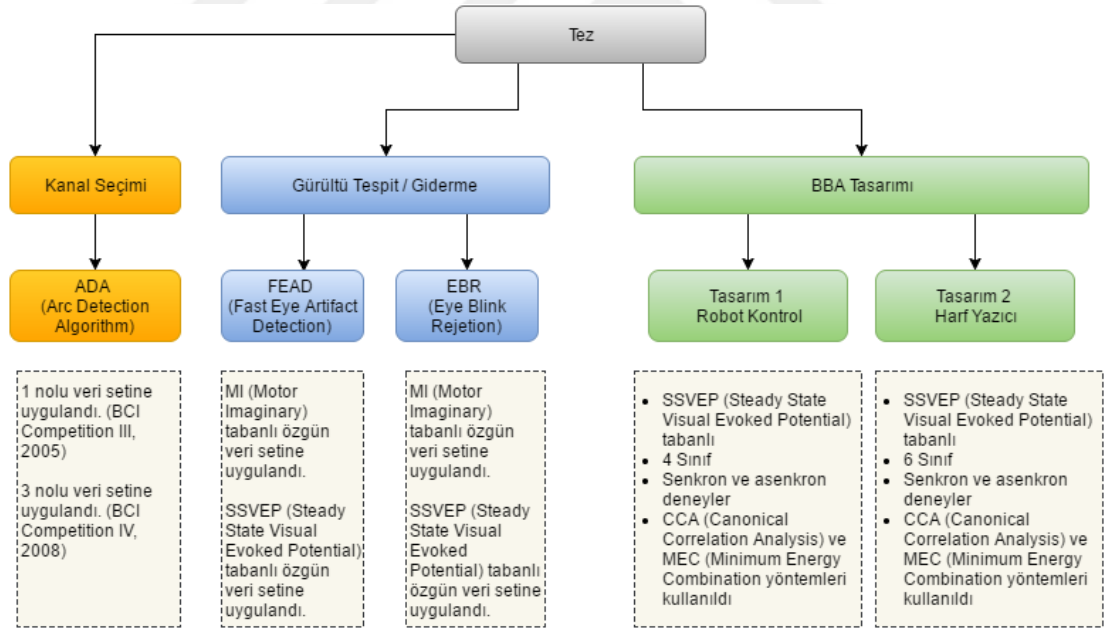
$$B_m = \frac{60}{T} C_n B_t \quad (4.20)$$

$$B_t = \log_2 N + p \log_2 p + (1 - p) \log_2 \left[\frac{1-p}{N-1} \right] \quad (4.21)$$

BÖLÜM 4

TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR

Tezin bu kısmında, bir önceki bölümde detaylı olarak anlatılan ve özgün olarak geliştirilmiş yöntemlerin kullanıldığı dört farklı BBA çalışması anlatılmaktadır. Deneysel çalışmaların öncesinde Karabük Üniversitesi, Tıp Fakültesi, Girişimsel Olmayan Klinik Araştırmalar Etik Kurulundan, kurul raporu alınmıştır. Tüm deneysel çalışmalar bu kurul raporu çerçevesinde gerçekleştirilmiştir. Tez kapsamında gerçekleştirilen BBA uygulamaların genel yapısı Şekil 4.1 ile verilmiştir.



Şekil 4.1. Tezin genel yapısı.

Şekil 4.1 de de genel hatlarıyla belirtilen tez çalışmaları kapsamında öncelikle BBA sistemlerine yönelik deneyim kazanmak için hazır veri setleri üzerinde ilk çalışmalar yapılmıştır. Bölüm 3 ile detayları verilen ADA algoritması, BCI Competition III ve IV yarışmalarında kullanılan veri setleri ile test edilmiş, başarılı sonuçlar elde

edilmiştir. Yine 3. Bölümde detaylı olarak anlatılan FAR, FEAD, EBR algoritmaları kendi özgün deneylerimiz sonucunda elde edilen MI ve SSVEP tabanlı veri setlerinde test edilmiştir. Yine tez çalışmaları kapsamında SSVEP tabanlı biri robot kontrolü diğeri de BBA kelime yazıcı olmak üzere iki farklı BBA tasarımı önerilmiş, uygulamalara ait performans analizleri yapılmıştır. Her iki BBA tasarımı ile de başarılı sonuçlar elde edilmiştir.

4.1. MOTOR HAREKET HAYALİ ÇALIŞMASI

EEG ve ECoG BBA sistemlerinde kullanılan en yaygın sinyal türleridir. Bu sinyaller beyin içindeki birçok nöronun ateşlenmesiyle oluşur. Sonuçta aynı etki ile oluşan bu sinyallerden EEG sinyallerinin elde edilmesi daha kolay ve güvenli iken, çözünürlüğü daha yüksek olan ECoG sinyallerinin elde edilmesi daha riskli ve zordur [1, 2]. Tezin bu bölümünde 2005 yılında üçüncüsü düzenlenen Beyin Bilgisayar Arayüzü yarışmasında (BCI Competition III) kullanılan ve Almanya'nın Tübingen Üniversitesi tarafından, bir hastadan cerrahi müdahale ile elde edilmiş veri setini oluşturan, ECoG sinyallerinin, farklı sınıflandırma yöntemleri kullanılarak sınıflandırılması gerçekleştirilmiştir.

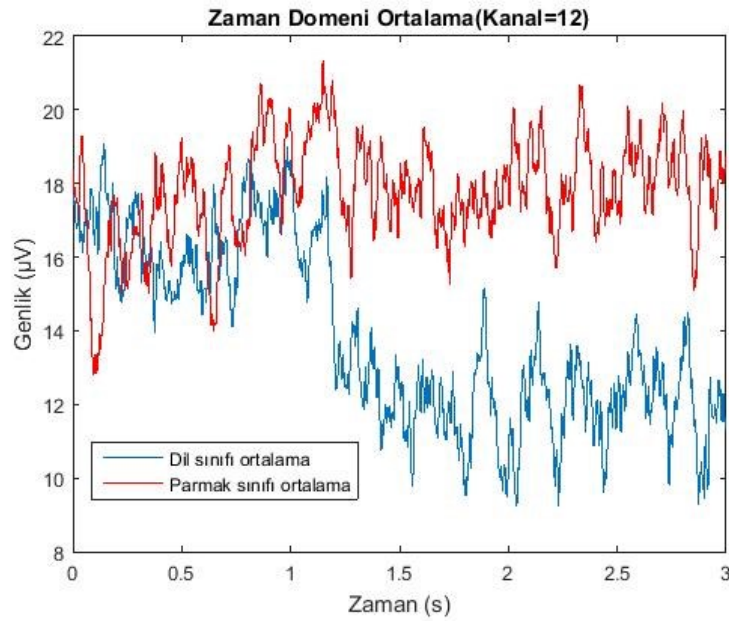
4.1.1. Veri Setinin Özellikleri

Kullanılan veri seti 2005 yılında üçüncüsü düzenlenen BCI Competition III yarışmasında kullanılan ve Almanya'nın Tübingen Üniversitesi tarafından sağlanan veri setidir (Dataset1). Veri seti 64 elektrotla kaydedilmiştir. Veri setinde deneğin 139 el ve 139 parmak resmine karşı ürettiği beyin sinyalleri 1000 Hz örnekleme frekansıyla her bir deneme 3 sn olacak şekilde kaydedilmiştir.

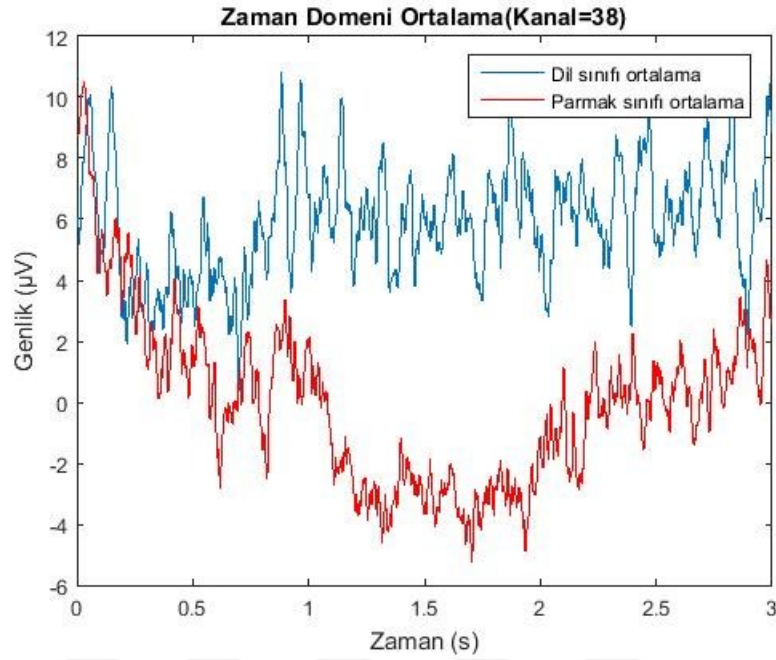
Yarıřmada toplam 278 adet el ve parmak denemesinin sınıflandırmada eğitim verisi olarak kullanılması istenmiş, bunun haricinde verilen ve etiketleri bilinmeyen 100 adet denemenin sonucunun tahmin edilmesi istenmiştir. Yarıřma sonucunda Tsinghua Üniversitesinden Qingguo Wei ve ekibi %91 doğruluk oranıyla 27 katılımcı arasından en yüksek sınıflandırma başarısını göstermiştir [86].

4.1.2. Kullanılacak Kanalların Belirlenmesi

Öznitelik çıkarmada kullanılacak en uygun kanal setinin belirlenmesinde her bir kanaldan elde edilen denemelerin zaman ve frekans spektrumu ortalamaları yol göstericidir. Şekil 4.2 ve Şekil 4.3'de sırasıyla 12 ve 38 nolu kanallara ait zaman domeni ortalamaları verilmiştir.



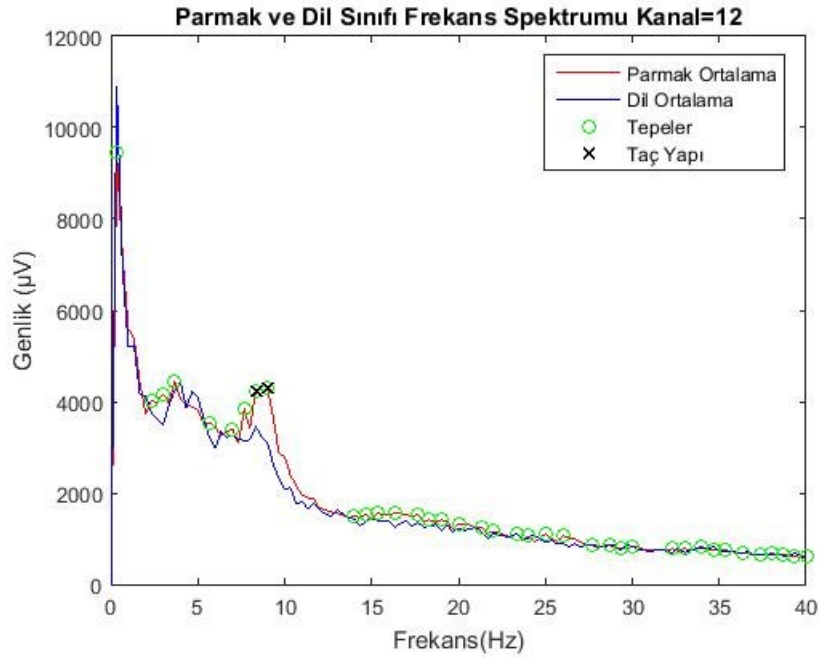
Şekil 4.2. Zaman domeni 12. kanal ortalaması.




Şekil 4.3. Zaman domeni 38. kanal ortalaması.

Şekil 4.2 ve Şekil 4.3'den de anlaşılacağı gibi iki sınıflı bu BBA çalışmasında 12 ve 38. kanallara ait dil ve parmak sınıfı denemelerinin ortalamaları farklılık göstermektedir. Parmak sınıfı ortalaması 12. kanal'da artan bir eğilim gösterirken, dil sınıfı ortalaması azalan bir eğilim içerindedir. 38. kanal için ise bu durumun tam tersi gözlemlenmektedir. BBA sistemlerinde kanal sayısı 8, 16, 32, 64 değerlerini alabilmekte, her bir kanalın önem derecesinin tespit edilmesi gerekmektedir. Bu çalışmada veri seti ile verilen 64 adet kanalın zaman ve frekans domeni ortalamaları incelenmiş ağırlıklı olarak 12 ve 38 numaralı kanalların sınıflandırmada kullanılmasına karar verilmiştir. Geliştirilen ADA algoritması ile en uygun kanal setinin belirlenmesinin hızlandırılması amaçlanmıştır. ADA algoritması frekans spektrumunda 10 Hz bölgesinde yay benzeri bir yapı aramaktadır. Şekil 4.4 ve Şekil 4.5 ile frekans spektrumu ortalamaları verilen 12 ve 38 numaralı kanallarda da benzer durum sözkonusudur. Ayrıca 12 ve 38 numaralı kanallara ait zaman domeni ortalamalarında da dil ve parmak sınıfları için ters yönde bir değişim olduğu gözlemlenmektedir. Bu çalışmada da veri seti ile verilen 64 adet kanalın zaman ve frekans spektrum ortalamaları incelenmiştir. 12, 21, 29, 30, 37, 38, 39 Numaralı kanalların özellikle frekans spektrumlarında 8-10 Hz bandı aralığında yay, taç benzeri yapı gözlemlenmiştir. ADA algoritması, görsel olarak, frekans spektrumunda

10 Hz frekans bölgesi yakınlarında, bu yay benzeri bir yapıya özgün matematiksel ve istatistiksel özelliklerden yola çıkılarak geliştirilmiştir. Algoritma sayesinde ilgili kanalların daha hızlı tespit edilmesi sağlanmış, görsel olarak elde edilen kanallar çok daha hızlı bir şekilde tespit edilebilmiştir. Şekil 4.4 ve Şekil 4.5 de 12 ve 38. Kanala ait dil ve parmak sınıflarında ADA algoritması tarafından tespit edilen yaylar gösterilmiştir.




Şekil 4.4. 12. Kanal parmak ve dil sınıfı frekans ortalamaları.




Şekil 4.5. 38. Kanal parmak ve dil sınıfı frekans ortalamaları.

Algoritma özellikle bizim kullandığımız gibi çok kanallı veri setlerinde motor hayal hareketi içeren kanalları hızlı bir şekilde belirleyebilmektedir. ADA kullandığımız veri setinin yanı sıra BCI competition IV yarışmasında kullanılan 3. veri seti ile de test edilmiş benzer sonuçlar elde edilmiştir. Bu veri seti 4 farklı yönde bileğini hareket ettiren deneklere ait MEG (Magnetoencephalography) kayıtlarını içermektedir. İlgili veri setinde 5 ve 7 numaralı kanallara ait ADA sonuç grafikleri sırasıyla Şekil 4.6 ve Şekil 4.7 ile verilmiştir.



Şekil 4.6. BCI competition IV 3. Veri seti kanal 5 ADA sonuçları.

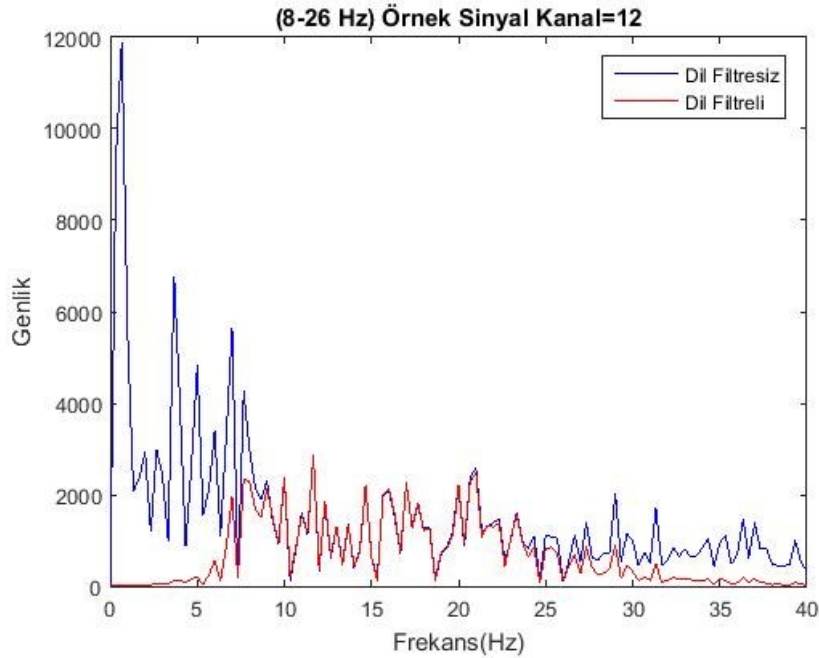


Şekil 4.7. BCI competition IV 3. Veri seti kanal 7 ADA sonuçları.

4.1.3. Sinyal Önışleme

4.1.3.1. Filtreleme

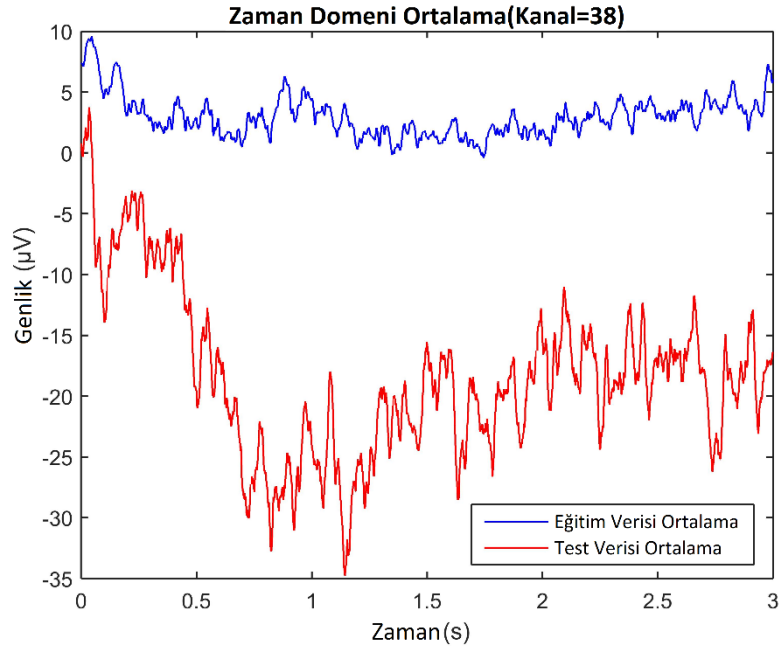
Uyanık insanlarda, duygusal girdilere maruz kalınmaz ve motor hareketleri üretilmezken, 8-12 Hz aralığında EEG sinyali gözlenmektedir [21, 87]. Bu boş durumda elde edilen sinyallere μ ritmi adı verilmektedir. 18-26 Hz arasında olanlara β ritmi adı verilmektedir. Hareket veya harekete hazırlık evrelerinde μ ve β ritimlerinde azalma gözlemlenmektedir. İlgili frekansları elde etmek için 4. Dereceden Butterworth band geçiren bir filtre kullanılmıştır. Tasarlanan filtre ile sinyal 8-26 Hz arası filtrelenmiştir. Filtreleme öncesi sinyali doğru akım bileşeni bastırılmıştır. Doğru akım bileşeni frekans domenindeki sıfırncı terime karşılık gelmektedir. Fourier dönüşümü ile frekans karşılığı alınan sinyalin sıfırncı bileşeni elimine edilmiştir. Bu sinyal ortalamasının asıl sinyalden çıkartılması anlamına gelir. Örnek olarak 8-26 Hz aralığında filtrelenmiş 12 numaralı kanalın frekans domeni görüntüsü Şekil 4.8'de verilmiştir.



Şekil 4.8. Filtrelenmiş sinyal 12. kanal frekans domeni.

4.1.3.2. Veri Setinin Standartlaştırılması

Veri setlerinin bir diğer olumsuz yanı da eğitim verileri ile test verilerinin farklı zamanlarda elde edilmiş olmasıdır. Bu farklılık, eğitim ve test verilerinin ortalamalarında genlik farkı olarak karşımıza çıkmaktadır. Eğitim ve test verilerinin genliklerinde karşılaşılan bu farklılık Şekil 4.9 ile gösterilmiştir.



Şekil 4.9. Eğitim ve test verileri ortalamalarındaki farklılık.

Eğitim verileri ile test verilerini arasındaki genlik farkını ortadan kaldırmak, verileri standartlaştırmak için Z skorundan faydalanılmıştır. Z skoru genel olarak verinin ortalamaya olan uzaklığını ifade etmektedir.

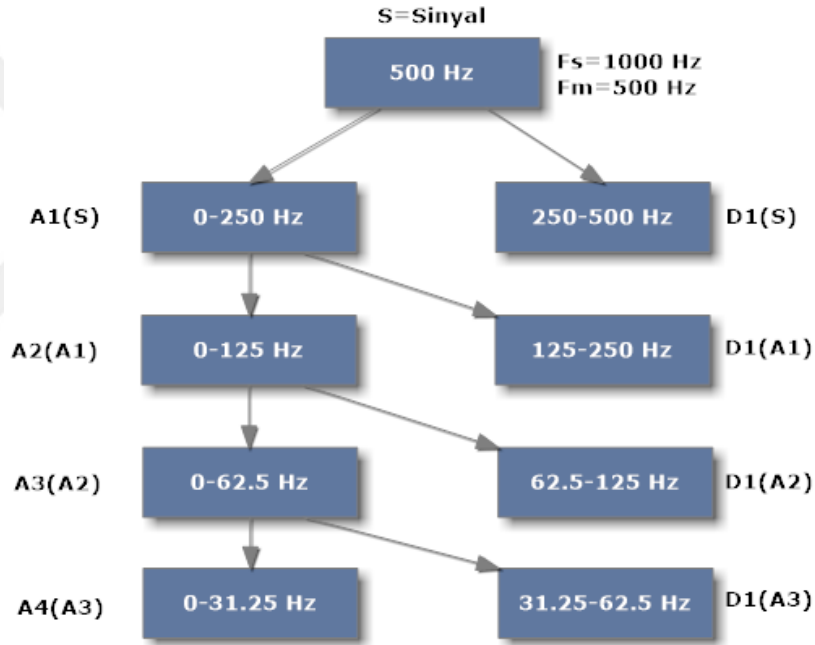
Z skoru, \bar{x} sinyal ortalamasını ve σ ortalama değeri ifade etmek üzere;

$$Z = \frac{x - \bar{x}}{\sigma} \quad (4.1)$$

Eşitlik 4.1 ile ifade edilebilir [88]. WT katsayılarından elde edilen her bir sinyal özelliğinin Eşitlik 4.1 yardımıyla z skorları hesaplanarak eğitim ve test kümeleri arasında standardizasyon sağlanmıştır.

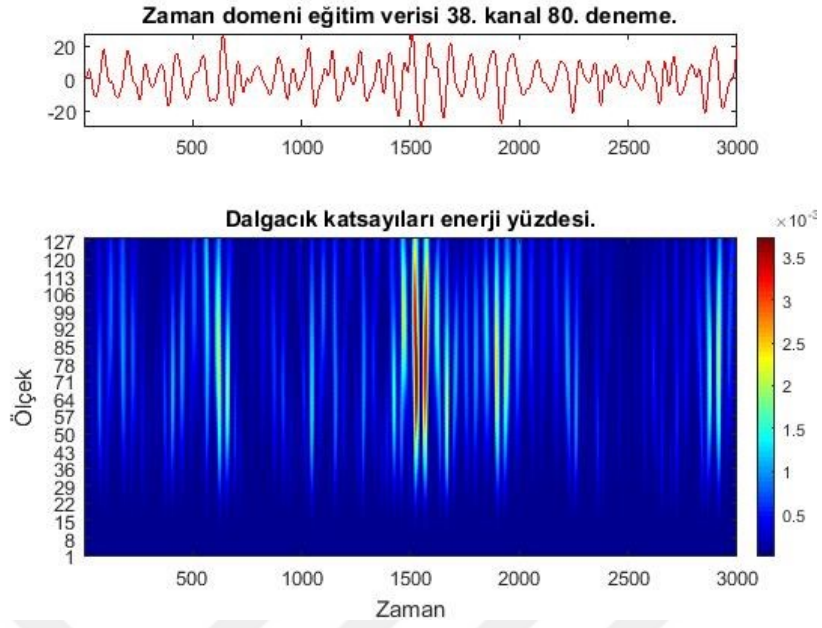
4.1.4. Özellik Çıkarımı

WT, ECoG sinyalinin sınıflandırma özelliklerinin belirlenmesinde kullanılmıştır. WT katsayıları alınırken Daubechies ana dalgacı kullanılmış ve 4. Dereceden yani art arda dört defa dönüşüm yapılarak WT katsayıları elde edilmiştir. Başlangıç sinyalimizin 1000 Hz örnekleme frekansına sahip olduğu düşünülürse sinyalin 500 Hz olan merkez frekansı temel alınarak 4. WT sonunda 0-31,5 Hz frekans aralığındaki sinyalimiz elde edilmiş olur. Şekil 4.10 ile her WT'den sonra elde edilen sinyal merkez frekansları verilmiştir. DWT sonucu elde edilen A yüksek frekanslı katsayıları D ise düşük frekanslı katsayıları temsil etmektedir.



Şekil 4.10 . Dalgacık dönüşümü sonuç frekansları.

Dalgacık katsayılarının enerji seviyelerini gösteren skalogram Şekil 4.11 ile verilmiştir.

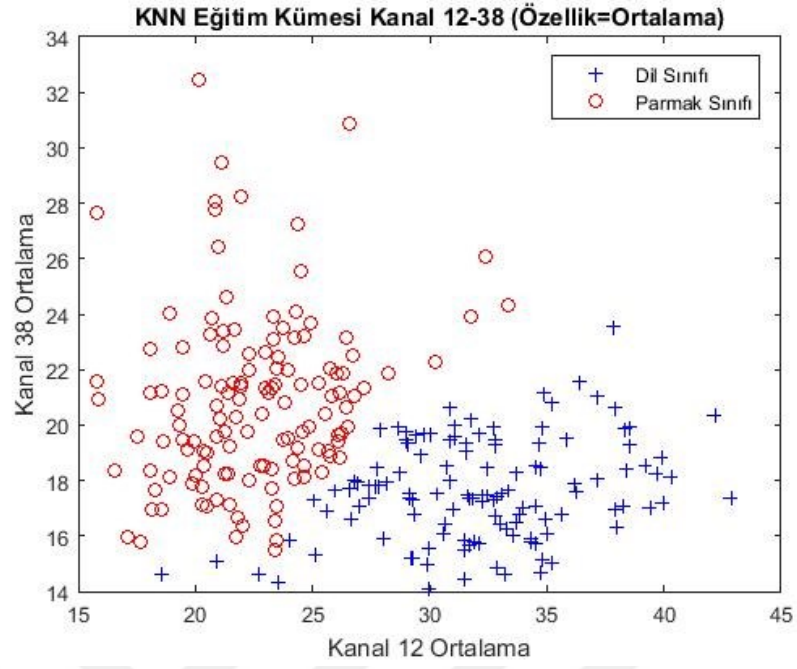


Şekil 4.11. Dalgacık katsayıları enerji durumu.

WT katsayıları elde edildikten sonra bu katsayıların maksimum, minimum, ortalama, standart sapma gibi özellikleri sinyalden belirlenebilir. Bu çalışmada WT katsayılarının maksimum, minimum, ortalama, standart sapma gibi özellikleri ayrı ayrı ve özellik gurupları halinde sınıflandırmada kullanılmıştır.

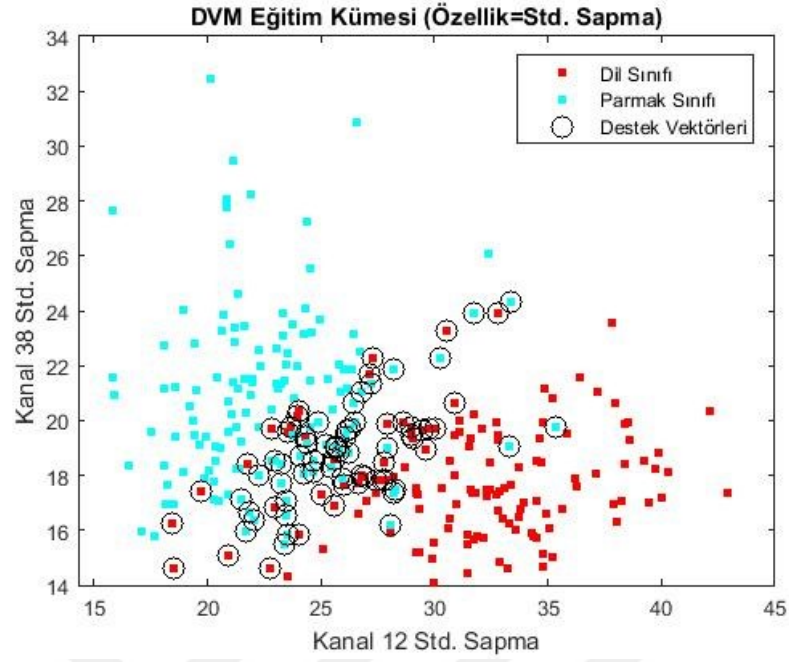
4.1.5. Sınıflandırma

Özellik çıkarımından elde edilen özellikler farklı sınıflandırıcılar ile karşılaştırmalı olacak şekilde bir dizi sınıflandırmaya tabi tutulmuştur. Belirlenen özellikler KNN, SVM, LDA ve Derin öğrenme yöntemlerinde sınıflandırma özelliği olarak kullanılmıştır. Eğitim verisinin 12 ve 38 numaralı kanallar için WT katsayı ortalamalarının kullanıldığı örnek bir KNN sınıflandırma grafiği Şekil 4.12 ile verilmiştir.




Şekil 4.12 KNN ile 12. ve 38. Kanal sınıflandırma.

Veri setinin eğitim ve test kümeleri SVM ile sınıflandırmaya tabii tutulmuştur. Şekil 4.13'de 12 ve 38 numaralı kanallara ait örnek bir SVM sınıflandırma sonuç grafiği özelliğine göre verilmiştir. Örnek sınıflandırmada WT katsayılarının standart sapması kullanılmıştır.



Şekil 4.13. SVM 12. 38. kanallar WC_std ile sınıflandırma.

LDA sınıflandırıcısı sonuçlarına örnek bir 3 kanallı sınıflandırma grafiği Şekil 4.14 ile verilmiştir.




Şekil 4.14. LDA ile sınıflandırma.

Bu çalışmada ayrıca geleneksel sınıflandırma yöntemlerinin dışında, daha çok iki veya daha çok boyutlu veri kümelerinde, özellikle de görüntü verilerinde yaygın olarak kullanılan derin öğrenme yöntemi, bir boyutlu nörolojik veri içeren ECoG sinyallerine uygulanmıştır. Tasarlanan derin yapay sinir ağı, sinyalin elde edildiği kanallar bir boyut ve o kanala ait üç saniyelik nörolojik veri bir boyut olmak üzere, bu iki boyutlu verinin oluşturduğu örüntü, derin ağın girişine eğitim ve test verisi olarak uygulanmıştır. Derin öğrenme basitçe 6 katmanlı bir ağ yapısı tasarlanmıştır. Ağ Matlab R2015a ortamında matconvnet kütüphanesi kullanılarak oluşturulmuştur. Tasarlanan ağın detayları Çizelge 4.1 ile genel yapısı ise Şekil 4.15 ile verilmiştir.

Çizelge 4.1. Derin ağ yapısı.

layer	0	1	2	3	4	5	6
type	input	conv	mpool	dropout	relu	conv	softmax
name	n/a	conv1		dropout2		fc1	
support	n/a	9	7	1	1	8x25	1
filt dim	n/a	1	n/a	n/a	n/a	2	n/a
num filts	n/a	2	n/a	n/a	n/a	2	n/a
stride	n/a	1	7	1	1	1	1
pad	n/a	0	0	0	0	0	0
rf size	n/a	9	15	15	15	64x183	64x183
rf offset	n/a	5	8	8	8	32.5x92	32.5x92
rf stride	n/a	1	7	7	7	7	7
data size	64x188	56x180	8x25	8x25	8x25	1	1
data depth	1	2	2	2	2	2	1
data num	50	50	50	50	50	50	1
data mem	2MB	4MB	78KB	78KB	78KB	400B	4B
param mem	n/a	656B	0B	0B	0B	3KB	0B



Şekil 4.15. Derin ağ yapısı.

Her biri 64 kanaldan oluşan 278 adet el ve parmak resmine karşılık üretilmiş ECoG verisi 188 örneğe alt örneklenmiş olarak 64x188 lik bir yapıda ağın girişine verilmiştir. İki boyutlu sinyal ilk olarak 9x9 boyutunda iki adet filtre ile konvolüsyon işlemine girmekte sonrasında 7x7 lik filtre ile maksimum havuzlama yapılmaktadır. Havuzlamadan elde edilen sinyal relu aktivasyon fonksiyonuna tabi tutulmaktadır. Aktivasyon fonksiyonu katmanı ile doğrusallığı giderilen sinyal tekrar 8x25 boyutlarında iki adet filtre ile softmaxloss katmanına gönderilmektedir. Softmaxloss katmanı yani türev katmanı, eğitim verisi etiketleriyle karşılaştırma yaparak ağa geri bildirim göndermekte ve ağı doğru eğitim eğilimini artırmaktadır. Havuzlamadan sonra eklenen dropout katmanı ile sinyal düzenliliği sağlanmaktadır. Bu çalışma, derin öğrenme yöntemi ile EEG sinyallerinin sınıflandırmasının gerçekleştirildiği ilk çalışmalardan biridir. Invasive olarak elde edilmiş ECoG sinyallerinin, geleneksel yöntemlerin dışında, başarısı ve popülerliği hızla artan, derin öğrenme yöntemiyle tasarlanmış bir konvüsyonel ağ ile sınıflandırma başarısı test edilmiştir. Derin öğrenme yönteminin kullanılmasıyla, geleneksel yöntemlerdeki kanal seçimi ve özellik çıkarımı gibi sınıflandırma basamakları, derin yapay sinir ağ tarafından gerçekleştirilmektedir. Toplam 278 adet eğitim verisinin eğitim ve doğrulama verileri sırasıyla %70 ve %30 olarak ayrılmış, ağı öğrenme oranı ise 0,0001 olarak belirlenmiştir. Tasarlanan ağ toplamda 200 iterasyonlu bir eğitime tabi tutulmuştur. Farklı iterasyonlardaki test eğitim başarısı Çizelge 4.19 ile verilmiştir. 100 Adet test verisi üzerinde %80 oranında bir sınıflandırma başarısı sağlanmıştır. Derin öğrenme ağlarının ihtiyaç duyduğu eğitim veri sayısı göz önünde bulundurulduğunda, daha fazla eğitim verisine sahip veri setlerinde, daha iyi sonuçlar elde edileceği düşünülmektedir.

4.1.6. Sonuçlar

4.1.6.1. KNN, SVM, LDA Sınıflandırma Sonuçları

BCI Competition III'de sunulan veriset1'in seçilen 12 ve 38 numaralı kanalları üzerinde ön işleme yapılarak sinyalin 8-26 Hz frekans bandı elde edilmiştir. Deneysel olarak farklı kanal ve özellik kombinasyonları ile sınıflandırmalar yapılmış ve %95 oranında bir sınıflandırma başarısı elde edilmiştir. Çalışmaya ilişkin sonuçlar

Çizelge 4.2 Çizelge 4.3, Çizelge 4.4, Çizelge 4.5, Çizelge 4.6, Çizelge 4.7, Çizelge 4.8 ve Çizelge 4.9 ile verilmiştir. Her bir çizelgede sınıflandırmada seçilen özellik seti, eğitim ve test başarıları belirtilmiştir.

Çizelge 4.2. Kanal 12, 38 bir özellik ile sınıflandırma sonuçları.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN	X					81.65	78
SVM	X					73.38	86
LDA	X					73.02	84
KNN		X				85.61	74
SVM		X				77.34	78
LDA		X				77.34	80
KNN			X			93.17	87
SVM			X			89.57	91
LDA			X			89.93	92
KNN				X		91.00	87
SVM				X		89.93	90
LDA				X		88.13	92
KNN					X	90.29	91
SVM					X	89.57	90
LDA					X	88.13	92

Çizelge 4.3. Kanal 12, 38 İki özellik sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN				X	X	90.65	87
SVM				X	X	89.93	90
LDA				X	X	88.45	92

Çizelge 4.4. Kanal 12, 38 Beş özellik ile sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN	X	X	X	X	X	91.73	93
SVM	X	X	X	X	X	86.69	94
LDA	X	X	X	X	X	90.29	94

Çizelge 4.5. Kanal 12, 38 ve 27 tek özellik sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN			X			95.32	89
SVM			X			87.77	93
LDA			X			89.57	92
KNN				X		91.01	85
SVM				X		88.85	91
LDA				X		89.93	92
KNN					X	91.37	88
SVM					X	88.13	92
LDA					X	88.85	92

Çizelge 4.6. Kanal 12, 38 ve 27 iki özellik sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN				X	X	91.37	87
SVM				X	X	88.13	91
LDA				X	X	87.41	93

Çizelge 4.7. Kanal 12, 38 ve 27 beş özellik sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN	X	X	X	X	X	91.73	88
SVM	X	X	X	X	X	85.97	93
LDA	X	X	X	X	X	90.29	93

Çizelge 4.8. Kanal 12, 38, 21 ve 29 tek özellik sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN	X					86.69	82
SVM	X					74.10	84
LDA	X					75.18	84
KNN		X				83.81	75
SVM		X				76.62	79
LDA		X				78.42	77
KNN			X			93.17	90
SVM			X			87.41	91
LDA			X			89.57	92
KNN				X		92.45	93
SVM				X		87.77	93
LDA				X		87.77	93
KNN					X	91.37	91
SVM					X	87.77	91
LDA					X	87.41	93


Çizelge 4.9. Kanal 12, 38, 21 ve 29 beş özellik sınıflandırma.

Yöntem	WC_min	WC_max	WC_mean	WC_std	FS_std	Eğitim Başarısı %	Test Başarısı %
KNN	X	X	X	X	X	88.84	89
SVM	X	X	X	X	X	87.05	95
LDA	X	X	X	X	X	89.56	93

Yapılan çalışmada, üç farklı sınıflandırma algoritması, sınıflandırmada kullanılan EEG kanalları ve bu kanallara ait farklı özellik guruplarıyla test edilmiştir. ECoG sinyallerindeki μ ve β ritimlerini beraberce gözlemleyebilmek için 8-26 Hz frekans bandı seçilmiştir. 8-26 Hz frekans bandını koruyacak şekilde 4. Dereceden WT uygulanarak sinyal örnekleri seyrekleştirilmiştir. Kanal seçiminde, görsel tabanlı kanal seçimi temeline dayalı olarak geliştirilen, ADA algoritması kullanılmış, ilgili algoritma hata kestirim yaklaşımıyla doğrulanmıştır. Veri seti her bir sinyalin z-skoru hesaplanarak standartlaştırılmış ve bu sayede eğitim ve test verilerindeki sınıflandırma başarısının daha tutarlı bir durum sergilediği gözlemlenmiştir. BBA sistemlerinde doğru kanal ve özelliklerin sistem başarısı artırdığı görülmüş, literatürde bu veri setiyle yapılan çalışmalarda karşılaşılan en yüksek sınıflandırma başarısının da üstünde, %95 oranında bir sınıflandırma başarısı elde edilmiştir.

4.1.6.2. Derin Öğrenme Ağı Sınıflandırma Sonuçları

Dil ve parmak hareketleri ile ilişkili veri seti, tasarlanan derin ağ yapısı ile de sınıflandırmaya tabii tutulmuştur. Şekil 4.16 ile tasarlanan derin konvolüsyonel ağın eğitim iterasyonlarına göre sınıflandırma başarımı gösteren grafik, Çizelge 4.10 ile de farklı iterasyonlardaki eğitim sayısı ve buna karşılık gelen, test başarısı yüzdeleri sunulmuştur.



Şekil 4.16. Derin ağ sınıflandırma sonuçları.

Çizelge 4.10. İterasyon sayısına göre derin ağ ile sınıflandırma sonuçları.

İterasyon Sayısı	Test Başarısı %
50	65
100	70
150	80
200	75

150 Adet test verisi üzerinde %80 oranında bir sınıflandırma başarıları sağlanmıştır. Derin öğrenme ağlarının ihtiyaç duyduğu eğitim veri sayısı göz önünde bulundurulduğunda, daha fazla eğitim verisine sahip veri setlerinde daha iyi sonuçlar elde edileceği öngörülmektedir. Ayrıca kanal seçimi ve özellik çıkarımı gibi sınıflandırma basamaklarının ağ tarafından otomatik olarak yapılır olması da derin konvüsyonel ağların kullanımına teşvik eden bir özelliktir.


4.2. GÖZ ARTIFAKTLARININ TEMİZLENMESİ

BBA sistemleri, nörolojik veya benzer sebeplerden ötürü kas sistemlerini kullanamayan insanlara destek vermeyi amaçlarken, sağlıklı insanlar için de günlük ve askeri alanlarda daha rahat ve hızlı bir iletişim imkânları sunmaktadır. BBA sistemleri tasarımlarında, EEG sinyallerindeki düşük sinyal gürültü oranı ve kişiye göre değişen sinyal farklılıkları temel olumsuzluklar olarak karşımıza çıkarken, bir diğer önemli konu ise istenmeyen kas hareketleri, göz kırpması ve buna benzer olumsuz sinyal etkilerinin ilgili sinyalden temizlenmesidir. Çalışmanın bu bölümünde bahsedilen istenmeyen EEG sinyallerinin nörolojik bilgi içeren EEG sinyallerinden temizlenmesi amaçlanmıştır. Bu çalışmada özgün olarak elde edilen, konuşma ve ses parçalarıyla ilgili oluşturulmuş bir EEG veri seti kullanılmıştır. Konuşma ile ilgili EEG veri setleri, deneğin bir şeyi konuştuğunu hayal ettiği sırada beyin sinyallerinin kayıt altına alınması ile elde edilir. Konuşma hayali birçok çalışmada kullanılmış, bu çalışmalarda ses birimi olarak harf, hece ve kelime kullanılmıştır [89, 90, 91, 92]. Bu bölümde genel yaklaşımdan farklı olarak Türkçe de “merhaba” ve “arkadaş” kelimelerini oluşturan 2 ve üç harften oluşan, 6 hece seçilmiş, bu ses parçalarının yazıldığını hayal edilmesi sırasında EEG sinyalleri kayıt altına alınmıştır. Veri seti üç denekten farklı oturumlarda, önceden belirlenen elektrot yerleşimleri ile elde edilmiştir. Deneklerden bilgisayar ekranından bir simülasyon aracılığıyla gördüğü ses parçalarını konuşma hayalinden farklı olarak, herhangi bir vokal kas hareketi yapmaksızın, yazdığını düşünmesi istenmiştir. Çalışmada kullanılan veri setindeki belirgin artefaktları (göz kırpma ve hareket vb.) tespit ve elimine etmek için bölüm 3’te detaylı olarak anlatılan, FEAD ve EBR algoritmaları kullanılmıştır. Çalışma göz artefakt tespiti ve temizlenmesinde özgün ve tatmin edici sonuçlar vermiştir.

4.2.1. Veri Setinin Özellikleri

Çalışmada üç denek görev almıştır. Veri seti, Türkçede merhaba ve arkadaş kelimelerini oluşturan “mer”, “ha”, “ba” ve “ar”, “ka”, “daş” hecelerinin bir bilgisayar simülasyonu ile rastgele deneğe gösterilmesi, deneğin de ekranda gördüğü ses birimini yazdığını düşünmesi esnasında, EEG sinyallerinin kayıt altına


alınmasıyla oluşturulmuştur. Kayıt 8 altın elektrot vasıtasıyla kafa derisinden ölçülmüş, elektrotlar uluslararası 10-20 sistemine göre konumlandırılmıştır. Şekil 4.17 ve Çizelge 4.10 da sırasıyla elektrot yerleşimleri ve elektrot numaraları verilmiştir. Kayıt 500 Hz örnekleme frekansıyla, her bir deneme 4 sn olacak şekilde kayıt altına alınmıştır. Şekil 4.18 ile kayıt prosedürü verilmiştir. Veri seti her bir denek için toplamda 240 adet etiketli hece verisi içermektedir. Psikofizyolojik sinyaller biyosinyal yükselteci (Bioradio, Great Lakes NeuroTechnologies, USA) ile toplanmıştır.



Şekil 4.17. Elektrot yerleşimi.

Çizelge 4.11. Elektrot numara ve isimleri.

Elektrot No	Elektrot Adı
1	FP1
2	FP2
3	AF3
4	AF4
5	C3
6	CZ
7	C4
8	PZ



Şekil 4.18. EEG kayıt prosedürü.

4.2.2. Sinyal Önışleme

EEG verilerindeki genlik uyumsuzluğunu ortadan kaldırmak için, veri setine önceki çalışmalarımızda da kullanılan, z-skor yöntemi ile standartlaştırma yapılmıştır. Toplam 8 kanaldan alınan 4 sn uzunluğunda 500 HZ örnekleme frekansına sahip EEG sinyalleri dinlenmeye ayrılan bölümün çıkarılmasıyla 3 sn uzunluğunda 1500 örnekten oluşan EEG sinyallerine dönüşmüştür. Tüm deneme sinyalleri 0,5-40 Hz arası band geçiren Butterworth tipi bir filtreden geçirilmiştir. Filtreleme öncesi sinyalin doğru akım bileşeni bastırılmıştır. EEG veri setine dalgacık gürültü giderme uygulanmıştır.

4.2.3. Sinyal Temizleme

EEG ölçümlerinde kafa derisine bağlanan elektrotlar nörolojik sinyal haricinde nörolojik sinyale karışan gözün hareketlerinden kaynaklanan EOG (elektrookulogram) sinyallerini de beraberce ölçebilir. Gerçek nörolojik verinin elde edilmesi için EOG sinyallerinin EEG sinyallerinden ayrılması gerekir. ICA ile farklı kaynakların toplamı olarak elde edilen sinyaller istatistiksel bağımsızlıklarına göre birbirlerinden ayrılabilir. Göz artefaktlarının temizlenmesinde kullanılan EBR yönteminde fast ICA yöntemi temel alınmıştır. Belirgin kas hareketleri ve dış etki sonucu oluşan olumsuz sinyal içeren denemeler, görsel izleme yaklaşımı ile elimine edilmiştir. Deneklere göre EBR algoritması ile EOG temizlemeye tabi tutulan sinyal

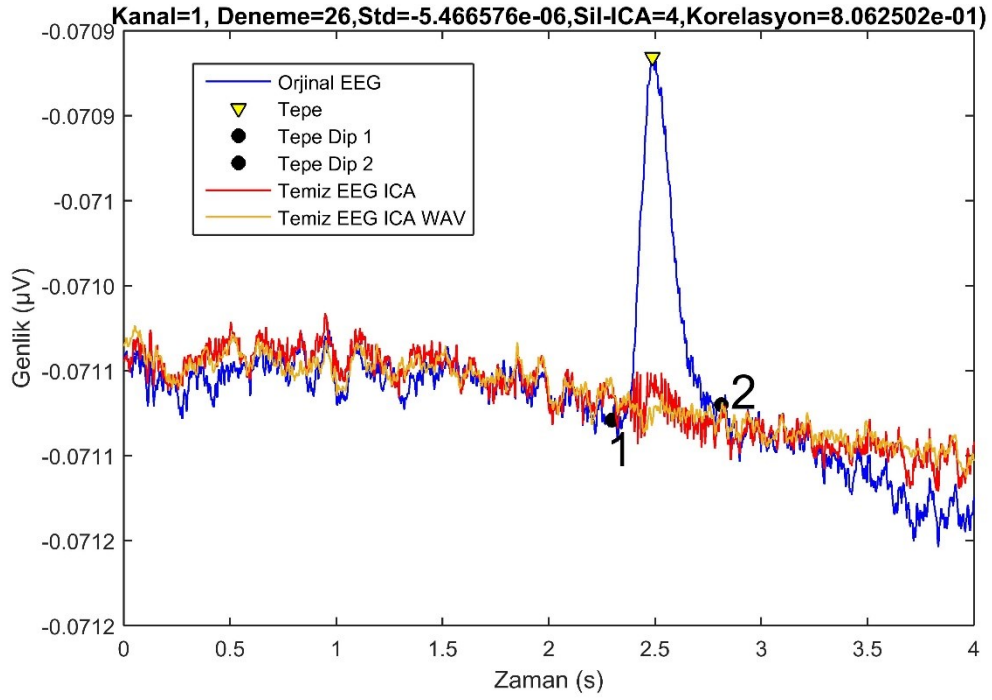
deneme sayıları, EOG içeren sinyal sayıları ve temizlemeden etkilenen bağımsız bileşen sayısı ortalamaları Çizelge 4.12 ile verilmiştir.

Çizelge 4.12. EEG veri seti.

Denek	Deneme Sayısı	EOG İçeren Deneme Sayısı	Etkilenen BB Sayısı
S1	182	145	4,3
S2	184	136	4,1
S3	191	162	3,9

4.2.4. Performans Analizi

Başlıbaşına artifakt temizleme için geliştirilmiş bir yöntem yoktur. Simule edilmiş verilerden yola çıkılarak elde edilmiş değerlendirme yöntemleri mevcuttur. Bunlar korelasyon katsayısı, standart sapma oranı (STD), üretilen sinyal ile orjinal sinyal arasındaki öklid uzaklığı gibi ölçümlerdir. Korelasyon katsayısı gerçek şeklin ne kadar iyi korunduğunu ifade ederken, std sinyal gücündeki değişimi ifade eder. Öklit mesafesi hem şekli hem de genliğin karşılaştırılmasına yardımcı olur. Korelasyon katsayısı ve STD oranı 1 değerine yaklaştıkça, öklit uzaklığı da 0 değerine yaklaşmasıyla iyi bir artifact temizliği ifade edilir [93]. Çalışmadaki değerlendirme 2 temel üzerine oturtulmuştur. Bu temellerden birincisi istenmeyen sinyal komponentinin nörolojik sinyalden ne kadar iyi temizlendiği, ikincisi orjinal sinyalin ne kadar iyi korunduğudur. Nöral bilginin korunmasındaki performansı değerlendirmek için orjinal EEG sinyalindeki artifakt içermeyen bölümler kullanılır. Bu bölümler artifakt kaldırma işleminden sonra bozulmadan kalmalıdır. Korelasyon katsayısı ve STD değerleri bu bölümler gözönünde bulundurularak hesaplanır [94]. EBR algoritmasının uygulanmasında ICA ile tespit edilen sinyal komponentlerinin elimine edilmesinde, ilgili komponentin sıfırlanması ve sinyalin WT ile elde edilen bileşenlerinin sıfırlanması şeklinde iki farklı yaklaşım uygulanmıştır. WT kullanılan yaklaşımda daha başarılı sonuçlar elde edildiği ve temizleme işleminden nörolojik sinyalin daha az bir kısmının etkilendiği gözlemlenmiştir. Şekil 4.19 ile örnek bir denemeye ait göz kırpması içeren sinyalin her iki yaklaşıma göre temizlenmiş sonuç sinyali verilmiştir.



Şekil 4.19. Orjinal ve temizlenmiş EEG.

Şekil 4.19 da göz kırpması içeren orjinal EEG sinyali, göz kırpmasına ait tepe ve yine bu tepeye ait dip noktalar ile EBR yöntemine ait hem klasik ICA tabanlı hem de WT uyarlanmış EOG temizleme çıktıları görülmektedir. EEG sinyali EBR sonucunda dört ICA bileşeni silinerek, %80'lik bir korelasyon oranıyla temizleme işlemini gerçekleştirmiştir.

4.2.5. Sonuçlar

Tez çalışmasının bu bölümünde EEG sinyallerinden EOG sinyali içerenlerin tespiti ve EOG sinyallerinin EEG sinyallerinden temizlenmesini sağlayan yeni bir EBR algoritması yaklaşımı önerilmiş, önerilen algoritma özgün bir veri seti ile test edilmiştir. Çizelge 4.13 ile test sonuçları verilmiştir. Önerilen yöntem göz kırpması içeren sinyal tespiti, ilgili sinyalin bağımsız bileşenlerine ayrılması, göz kırpmasını meydana getiren bağımsız bileşenlerin tespiti, göz kırpmasını meydana getiren sinyallerin orjinal sinyalden çıkarılması gibi tüm işlemleri tamamıyla otomatik olarak gerçekleştirmektedir.

Çizelge 4.13. EBR sonuçları.

Ölçüm	S1		S2		S3	
	ICA	EBR	ICA	EBR	ICA	EBR
Korelasyon Katsayısı ($\times 10^{-2}$)	71,31±13,65	81,62±8,27	62,51±12,23	75,61±8,37	65,36±12,30	78,08±8,52
STD Farkı ($\times 10^{-6}$)	-4,77±0,16	-5,91±0,17	85,09±0,10	93,29±8,41	2,81±9,86	-5,91±0,17

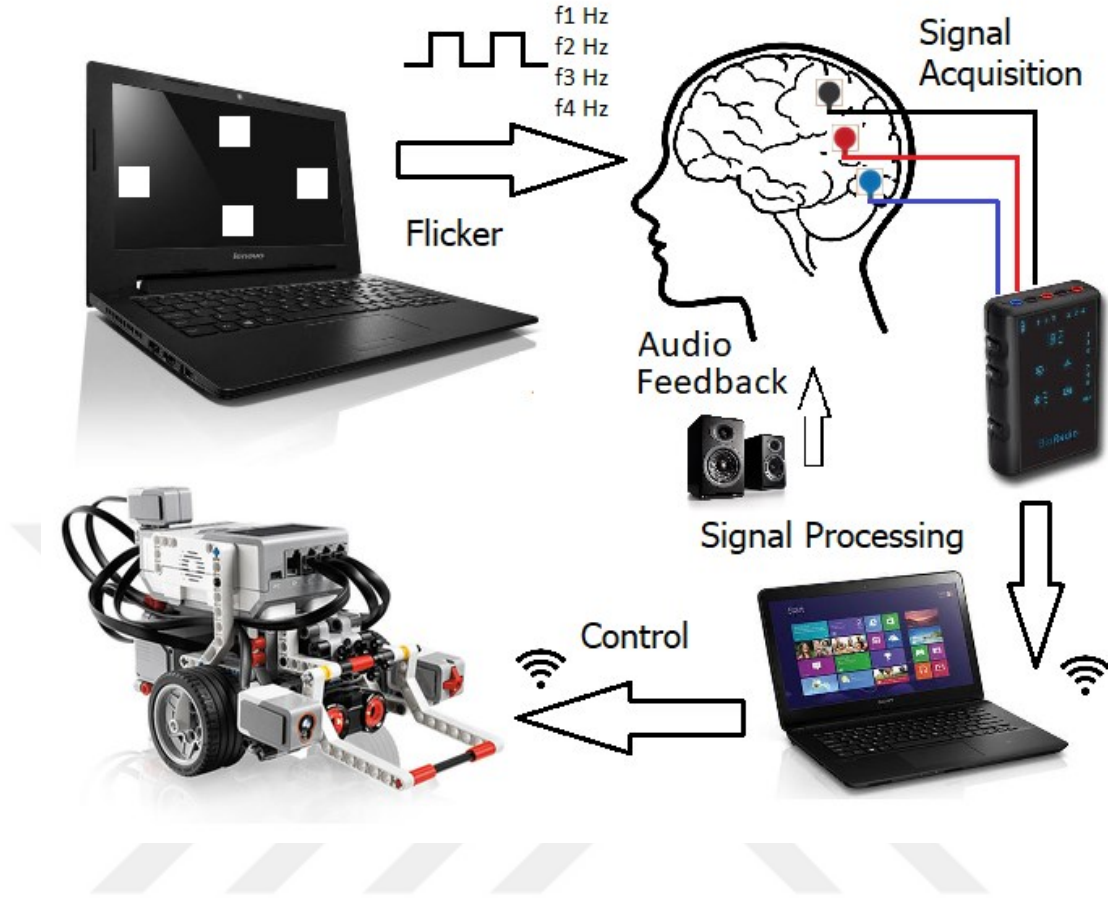
Algoritma herhangi bir EOG referans sinyaline ihtiyaç duymamaktadır. Böylece fazladan referans elektrot kullanılmasına da ihtiyaç duyulmamaktadır. EBR fastICA yöntemiyle EEG sinyalini analiz etmektedir. Farklı ICA algoritmaları ile daha değişik sonuçlar elde edilebilir. Ancak seçilen yöntemin paralel programlamaya uygunluğu ile sonraki çalışmalarda performans artışı amaçlanmaktadır. EBR algoritmasına uyarlanan WT ile klasik ICA ile EOG temizleme yöntemlerine göre yaklaşık %12'lik oranın üzerinde bir korelasyon iyileştirmesi sağlanmış ve %80'in üzerinde sinyal benzerlik oranı yakalanarak oldukça başarılı bir EOG temizliği yapılmıştır.

4.3. DURAĞAN GÖRSEL UYARILMIŞ POTANSİYEL ÇALIŞMASI

Durağan Görsel Uyarılmış Potansiyel (SSVEP) tabanlı BBA sistemleri kullanıcıya bir görsel uyartım gönderen, bu görsel uyartım sinyaline karşılık kullanıcıdaki değişimi tespit etmeye çalışan BBA sistemleridir. Genel olarak farklı frekanslardaki görsel uyartımları kullanan bu sistemler için en verimli frekans bandı 5-20 Hz frekans bandıdır. [95, 96]. Bu sinyaller sonucu kullanıcıda oluşan değişim kafa derisinden tespit edilebilmektedir. SSVEP BBA sistemi toplanan sinyali analiz edip yorumlamaktadır. Sistemlerin başarısı hız, doğruluk ve sınıflandırılacak hedef sayısına bağlı olan information transfer rate (ITR) ile ölçülür [97, 98, 99]. Örnek olarak altı hedefe sahip BBA sistemlerinde ortalama doğruluk % 95,3 ve ITR oranı da $58 \pm 9,6$ bit/dk olarak bildirilmiştir [100]. Başka bir çalışmada bu değerler % 96,79 ve 61,70 bit/dk olarak bildirilmiştir [99]. Yaşlı ve genç gurupları arasında yapılan başka bir çalışmada da ITR sırasıyla 16.10 bit/dk ve 27.36 bit/dk olarak rapor edilmiştir [101]. Yine başka bir SSVEP tabanlı BBA sisteminde ITR oranı 25.69 bit/dk ve 39.87 bit/dk aralığında bildirilmiştir [102]. ITR'nin dışında bu sistemlerin

genel başarısını etkileyen kullanıcı dostu bir arayüze sahip olması, artifakt duyarlılığı gibi özellikler de vardır.

Bu çalışmada 4 hedefe sahip SSVEP tabanlı bir BBA sistemi tasarlanmıştır. Toplamda 4 sağlıklı denek çalışmada görev almıştır. Deneyler asenkron ve senkron olmak üzere iki farklı tipte gerçekleştirilmiştir. Asenkron deneylerle detaylı sinyal analizi hedeflenmiş, senkron deneylerde deneklerden, Lego Midstorm EV3 robotunu 12 adımdan oluşan bir yolda, sadece beyin sinyallerini kullanarak yönlendirmesi istenmiştir. Sistemin genel yapısı Şekil 4.20 ile verilmiştir. Önceki çalışmalarımızda geliştirdiğimiz FEAD algoritması yeni sisteme uyarlanarak sistemin aktif ve pasif hale getirilmesi belirlenen göz kırpması paterni ile sağlanmıştır. Uyarlama sistem kullanılabilirliğini artırmıştır. Çalışmada 0,2 sn aralıklı, bilgisayar faresinin çift tıklanmasına benzer, bir göz kırpma paterni aktivasyonda kullanılmıştır. Farklı göz kırpma paternleri sisteme farklı komutlar olarak atanabilmektedir. Deneyler sonucu elde edilen EEG verisi farklı sinyal pencere uzunluklarında MEC ve CCA yöntemleri ile analiz edilmiş ve bu farklı sinyal pencere uzunluklarındaki ITR değerleri hesaplanmıştır. Sonuç olarak, SSVEP tespit noktasında MEC ve CCA yöntemleri benzer başarı göstermesine karşın MEC yönteminin biraz daha iyi sonuç verdiği gözlemlenmiştir. Senkron deneylerde deneklerde biri ile 133 bit/dk lık ITR oranı 0,9 sn'lik sinyal pencere genişliği ile yakalanmıştır. Bu değer literatürde yayınlanan önceki ITR değerlerinden daha iyi bir değerdir.




Şekil 4.20. SSVEP tabanlı sistemin genel yapısı.

4.3.1. Veri Toplama

Veriler yaş ortalaması 35,75 olan dört sağlıklı denekten toplanmıştır. Deneyler asenkron ve senkron şekilde gerçekleştirilmiştir. Asenkron deneyler denek LCD (1366 x 768 çözünürlük, 60 Hz ekran tazeleme oranı) bir bilgisayar ekranında dört farklı frekansta (6,66 Hz, 7,50 Hz, 8,57 Hz, 10 Hz) titreşen 100x100 piksel boyutundaki beyaz renkteki kareye odaklanmıştır. Genel olarak farklı frekanslardaki görsel uyarımları kullanan bu sistemler için en verimli frekans bandı 5-20 Hz frekans bandıdır. [95, 96]. Belirlenen frekanslar hem bu aralıkta olması bakımından hemde 60 Hz olan ekran tazeleme oranımızla uyumlu olduğu için seçilmiştir [40, 96]. Asenkron deneylerde denegin hangi kareye odaklanacağı, sesli komut ile kendisine bildirilmiştir. Deneylerde biri I7 2,8 GHz işlemcili, diğeri I3 2,27 GHz işlemcili iki farklı dizüstü bilgisayar kullanılmıştır. Bunlarda ilki simülasyon bilgisayarı, diğeri sinyal işleme görevini üstlenmiştir. Her iki bilgisayarda Microsoft

Windows 10 işletim sistemiyle çalışmaktadır. Denekler simülasyon ekranından yaklaşık olarak 50 cm uzağa oturmuşlardır. Deney sırasındaki beyin aktivitesi 8 altın elektrot ile 500 Hz örnekleme frekansıyla, BioRadio (Great Lakes NeuroTechnologies, USA) yükselteci kullanılarak, her bir deneme 5 sn olacak şekilde kayıt altına alınmıştır. Uluslararası 10-20 sistemine göre belirlenen elektrot yerleşim biçimi ve deneylerde kullanılan BioRadio cihazı sırasıyla Şekil 4.21 ve Şekil 4.22 ile verilmiştir.



Şekil 4.21. Elektrot yerleşimi.



Şekil 4.22. BioRadio cihazı.

Veri seti her bir denek için sınıf başına 56 adet etiketli veri barındırmaktadır. Kodlama MATLAB 2105a ortamına Psychtoolbox ve Lego Mindstorms EV3 Support kütüphaneleri kullanılarak gerçekleştirilmiştir. Senkron deneyde kullanılan robot ve BBA sisteminin arayüzü Şekil 4.23 ve Şekil 4.24 ile sunulmuştur.



Şekil 4.23. Robot Lego EV3.



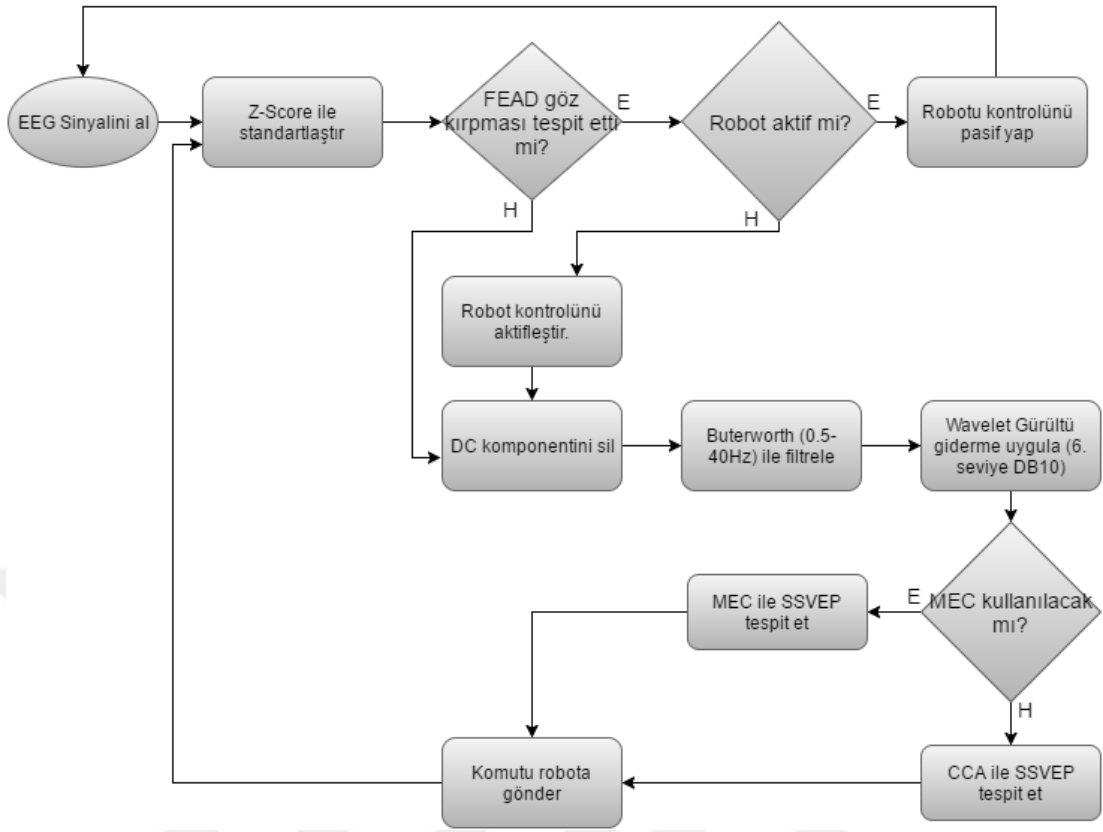
Şekil 4.24. SSVEP BBA Sistem arayüzü.

4.3.2. Sinyal Önışleme

Verilerin standartizasyonu için z-skor yönteminden faydalanılmıştır. Toplam 8 kanaldan alınan 5 ve 2,5 sn uzunluğunda, 500 Hz örnekleme frekansına sahip EEG sinyalleri, 0,5-40 Hz arası band geçiren Butterworth tipi bir filter ile filtrelenmiştir. Filtreleme öncesi sinyalin doğru akım bileşeni bastırılmıştır.

4.3.3. Sinyal İşleme

SSVEP 'lerin tespit edilmesi için MEC ve CCA yöntemleri kullanılmış, her iki yöntemin başarısı farklı pencere uzunluklarında test edilmiştir. SSVEP'lerin tespit edilmesine yönelik sinyal işleme basamakları Şekil 4.25 ile verilmiştir.



Şekil 4.25. SSVEP robot sinyal işleme basamakları.

4.3.4. Sistem Performansının Değerlendirilmesi

Sistem performansının değerlendirilmesinde dakikada iletilen bit oranı veya bilgi transfer hızı olarak adlandırılan ITR değeri hesabı kullanılmıştır. Bu değer 3. Bölümde anlatılan şekilde her bir sinyal pencere genişliği ve denek için ayrı ayrı hesaplanmıştır.

4.3.5. Deneysel Sonuçlar ve Değerlendirme

Deneyler asenkron ve senkron şekilde gerçekleştirilmiştir. MEC ve CCA yöntemlerinin kullanıldığı asenkron deneylerdeki her bir deneğe ilişkin sonuçlar Çizelge 4.14, Çizelge 4.15, Çizelge 4.16 ve Çizelge 4.17 ile verilmiştir.

Çizelge 4.14. Asenkron deney sonuçları denek1.

Signal Uzunluğu (sn)	CCA		MEC	
	Doğruluk (%)	ITR (bit/dk)	Doğruluk (%)	ITR (bit/dk)
2	93,30	46,18	95,98	50,80
1.5	89,29	53,56	93,30	61,57
1	85,27	69,80	91,96	88,15
0.9	80,36	64,93	91,07	94,96
0.8	78,13	67,16	89,29	100,42
0.7	75,89	70,38	87,95	109,55
0.6	74,55	77,84	84,82	114,51
0.5	65,18	61,88	82,14	124,80
0.4	63,84	72,43	72,32	106,54
0,3	51,34	45,85	63,39	94,44
0,2	36,61	14,29	49,55	60,15
0,1	25,45	0,05	27,23	1,13

Çizelge 4.15. Asenkron deney sonuçları denek2.

Signal Uzunluğu (sn)	CCA		MEC	
	Doğruluk (%)	ITR (bit/dk)	Doğruluk (%)	ITR (bit/dk)
2	94,64	48,41	95,54	49,98
1.5	83,93	44,37	91,07	56,98
1	83,48	65,50	89,73	81,59
0.9	78,13	59,69	86,16	80,04
0.8	74,55	58,38	83,93	83,19
0.7	73,66	64,35	80,36	83,48
0.6	72,32	71,03	73,66	75,07
0.5	62,50	54,14	75,89	98,53
0.4	58,48	54,42	64,73	75,69
0,3	45,09	27,33	56,70	65,33
0,2	30,36	3,17	38,39	18,83
0,1	20,54	4,80	21,43	3,05

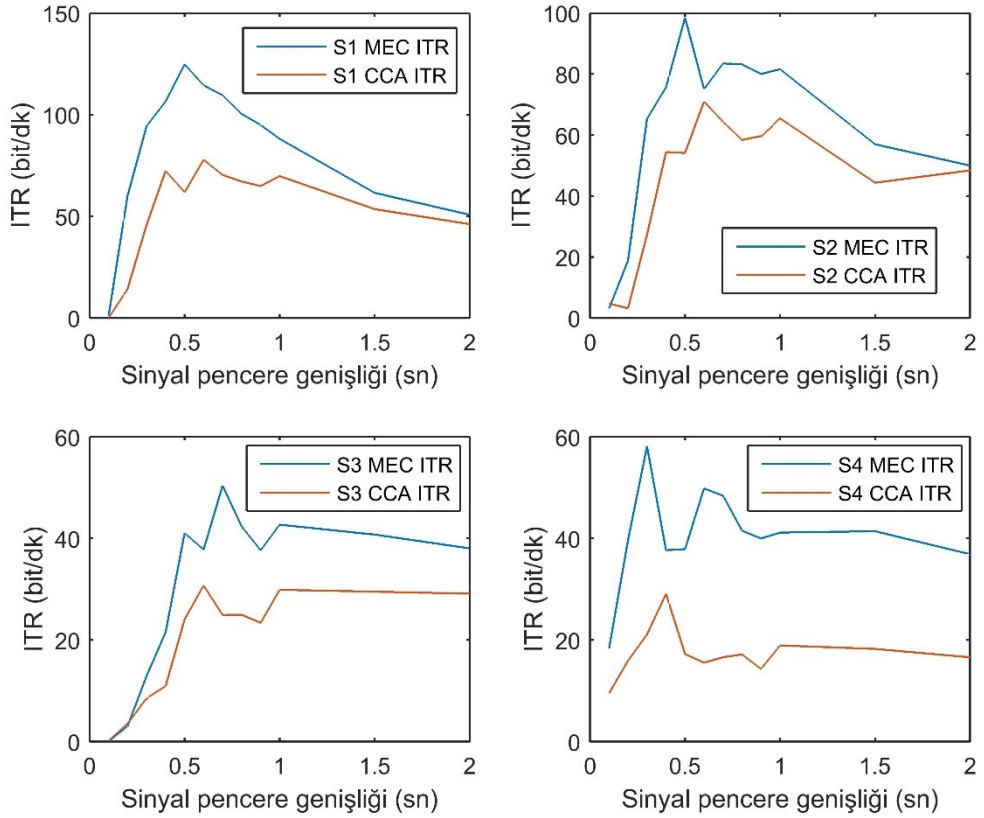
Çizelge 4.16. Asenkron deney sonuçları denek3.

Signal Uzunluğu (sn)	CCA		MEC	
	Doğruluk (%)	ITR (bit/dk)	Doğruluk (%)	ITR (bit/dk)
2	80,26	29,12	87,72	38,04
1.5	73,25	29,52	81,58	40,75
1	64,47	29,89	72,37	42,70
0.9	57,89	23,38	67,11	37,65
0.8	57,02	24,98	67,11	42,36
0.7	54,82	24,92	67,98	50,40
0.6	55,70	30,73	59,21	37,81
0.5	49,56	24,07	57,46	41,02
0.4	39,47	10,93	45,61	21,53
0,3	35,96	8,54	38,60	12,93
0,2	30,70	3,58	30,26	3,06
0,1	24,12	0,18	25,44	0,04

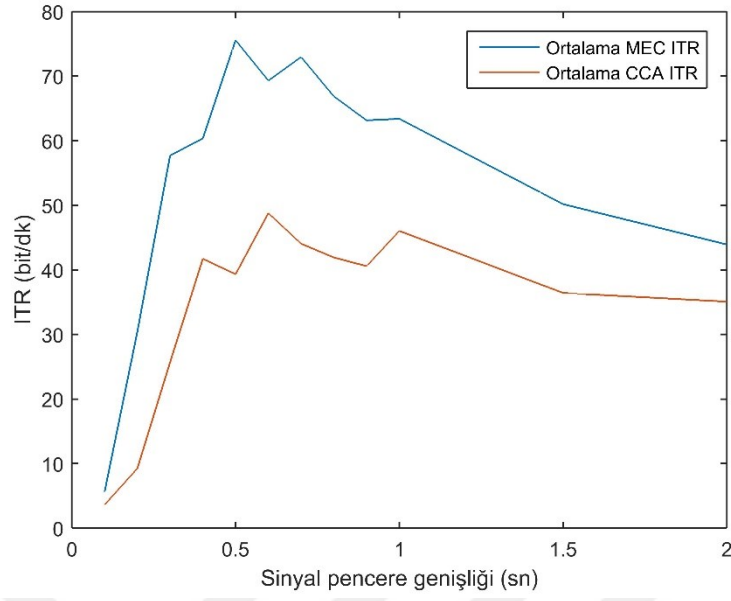
Çizelge 4.17. Asenkron deney sonuçları denek4.

Signal Uzunluğu (sn)	CCA		MEC	
	Doğruluk (%)	ITR (bit/dk)	Doğruluk (%)	ITR (bit/dk)
2	66,67	16,60	86,84	36,89
1.5	62,72	18,25	82,02	41,41
1	56,14	18,94	71,49	41,15
0.9	50,44	14,30	68,42	39,98
0.8	51,32	17,17	66,67	41,50
0.7	49,12	16,61	67,11	48,41
0.6	46,49	15,55	64,47	49,82
0.5	45,61	17,23	56,14	37,89
0.4	49,12	29,08	52,63	37,68
0,3	42,54	21,09	54,82	58,14
0,2	37,28	15,94	44,74	39,63
0,1	31,58	9,48	34,21	18,27

ITR değerinin sinyal pencere genişliklerine göre değişimi Şekil 4.26 ile verilmiştir. Her iki SSVEP tespit metodu için ortalama ITR değerleri Şekil 4.27 ile verilmiştir. 0.5-1 sn sinyal pencere aralığında tüm denekler için en yüksek ITR değerleri yakalanmıştır.



Şekil 4.26. Pencere genişliklerine göre ITR değerleri.



Şekil 4.27. Ortalama ITR değerleri.

Senkron deneyler tekrarlanarak, en yüksek ITR değerini sağlayan sinyal pencere genişliği tespit edilmeye çalışılmıştır. CCA ve MEC yöntemleriyle elde edilen senkron deney sonuçları Çizelge 4.18 ve Çizelge 4.19 ile verilmiştir.

Çizelge 4.18. Senkron deney CCA sonuçları.

Sinyal Uzunluğu (s)	S1 Doğruluk %	S1 ITR bit/sn	S2 Doğruluk %	S2 ITR bit/sn	S3 Doğruluk %	S3 ITR bit/sn	S4 Doğruluk %	S4 ITR bit/sn	Ortalama Doğruluk %	Ortalama ITR bit/sn
2	100,00	60,00	100,00	60,00	100,00	60,00	100,00	60,00	100,00	60,00
1.5	100,00	80,00	100,00	80,00	100,00	80,00	100,00	80,00	100,00	80,00
1	100,00	120,00	100,00	120,00	91,67	87,25	91,67	87,25	95,83	103,62
0.9	91,67	96,94	83,33	72,39	83,33	72,39	83,33	72,39	85,42	78,53
0.8	91,67	109,06	91,67	109,06	75,00	59,44	83,33	81,44	85,42	89,75
0.7	83,33	93,07	83,33	93,07	66,67	47,43	75,00	67,93	77,08	75,37

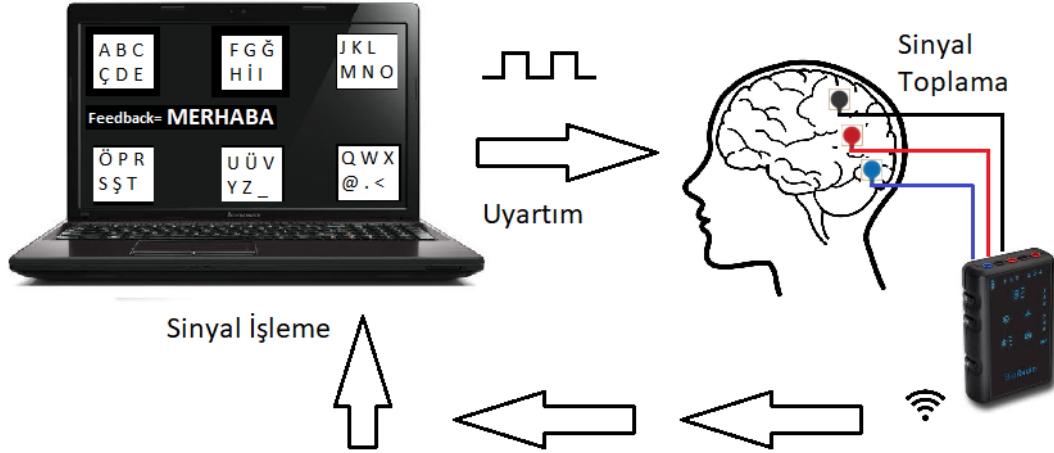
Çizelge 4.19. Senkron deney MEC sonuçları.

Sinyal Uzunluğu (s)	S1 Doğruluk %	S1 ITR bit/sn	S2 Doğruluk %	S2 ITR bit/sn	S3 Doğruluk %	S3 ITR bit/sn	S4 Doğruluk %	S4 ITR bit/sn	Ortalama Doğruluk %	Ortalama ITR bit/sn
2	100,00	60,00	100,00	60,00	100,00	60,00	100,00	60,00	100,00	60,00
1.5	100,00	80,00	100,00	80,00	100,00	80,00	100,00	80,00	100,00	80,00
1	100,00	120,00	100,00	120,00	100,00	120,00	100,00	120,00	100,00	120,00
0.9	100,00	133,33	91,67	96,94	83,33	72,39	91,67	96,94	91,67	99,90
0.8	91,67	109,06	91,67	109,06	83,33	81,44	91,67	109,06	89,58	102,15
0.7	83,33	93,07	83,33	93,07	75,00	67,93	75,00	67,93	79,17	80,50

SSVEP BBA sistemlerinde sinyal pencere uzunluğu ve doğruluk en önemli sistem performans parametreleridir. Bu çalışma SSVEP tabanlı bir robot kontrol BBA sistemi ve bu sistemin performans analizini sunmaktadır. Farklı sinyal pencere uzunluklarına göre CCA ve MEC yöntemleriyle tespit edilen SSVEP sinyalleri sistem performansının değerlendirilmesinde kullanılmıştır. Deneyler esnasında EEG sinyallerinden göz kırpmaya sayılarını tespit edebilen FEAD algoritmasıyla sistem aktivasyonu sağlanarak sistem kontrolü ve kullanılabilirliği artırılmıştır. Yakın doğruluk sonuçları gözlemlenen her iki yöntemden MEC yöntemini biraz daha iyi sonuçlar verdiği gözlemlenmiştir. Senkron deneylerde, MEC yöntemi kullanılarak, oksipital bölge kanallarından sadece O1, O2 ve Oz kullanılarak 133 bit/dk lık ITR değeri yakalanmıştır. Belirtilen ITR değeri literature göre oldukça başarılı bir sonuçtur. Çizelge 4.18 ve Çizelge 4.19 de başarılı sınıflandırma sonuçları vurgulanmıştır. Çizelge 4.19 de belirtildiği gibi tüm denekler sinyal pencere genişliği 2, 1,5 ve 1 sn için önceden tanımlanmış robot yolunu hatasız tamamlamışlardır. 1 ve 0,8 s sinyal pencere aralığında 100 bit/sn nin üzerinde ITR değerleri elde edilmiştir. Çalışma ile robot hareketlerinin denekleri motive ettiği senkron deneylerin, asenkron deneylerden daha başarılı olduğu gözlemlenmiştir. Doğal olarak sakin insanlarda SSVEP tespitinin daha kolay olduğu, stresin sinyal tespitini olumsuz etkilediği de gözlemler arasındadır.

4.4. TÜRKÇE TEMELLİ BEYİN BİLGİSAYAR YAZICISI

Bu çalışma tasarladığımız ikinci SSVEP tabanlı BBA sistemidir. Sistem bir bilgisayar ekranında farklı frekanslarda titreşen 100 x 100 piksel boyutunda 6 beyaz kutucuk ve bu kutucukların içinde, kullanıcının tercihleri doğrultusunda kullanıcılarla etkileşimli değişen sembollerden oluşmaktadır. Kullanıcı her bir kutuda 6 adet sembol olan bu BBA sisteminde, sadece iki seçim ile istediği hedefe bakarak ekrana bir sembol yazdırabilmektedir. Kullanıcı ilk olarak 6 kutudan hangisine yoğunlaşmış ise, ilk seçimin sonunda tüm kutu içerikleri temizlenip, ilgili kutu içerisindeki 6 adet sembol, her kutuya bir sembol gelecek şekilde yerleştirilir. Kullanıcının yaptığı 2. Seçim ile ekrana yazdırılmasını istediği sembolü belirler. Bu şekilde, kullanıcı sadece ekranda istediği kutucuklara odaklanarak, herhangi bir kasını kullanmadan, istediği metni bilgisayar ekranına yazdırabilir. Sistemin genel yapısı Şekil 4.28 ile verilmiştir.



Şekil 4.28. Türkçe temelli beyin bilgisayar yazıcısı.

4.4.1. Veri Toplama


Deneyle ilk önce uyartım ekranı sağlama ve sinyal işleme yapan iki ayrı bilgisayar tarafından gerçekleştirilmiştir. İlk deneyde TV ekranının tam ortasına bir aparat yardımı ile yerleştirilen 13-inch ekran boyutuna sahip bir dizüstü bilgisayar

kullanılmıştır. TV ekranındaki uyartım simülasyonu i7 işlemcili başka bir bilgisayarla sağlanmıştır. İlk deneylerden bir çalışma anı Şekil 4.29 ile verilmiştir.



Şekil 4.29. İlk deney örnek bir görüntü.

Sonrasında her iki görevi de tek başına üstlenen i7 2,8 GHz işlemciye sahip tek bir dizüstü bilgisayar kullanılarak sisteme esneklik sağlanmıştır. Simülasyon ve sinyal işleme görevlerinin beraberce üstlenen dizüstü bilgisayar LCD 1366 x 768 çözünürlükte, 60 Hz ekran tazeleme oranına olan bir ekrana sahiptir. Deneylerde ekranda bulunan altı farklı frekansta (6,66 Hz, 7,50 Hz, 8,57 Hz, 10 Hz, 12 Hz, 5.45 Hz) titreşen 100x100 piksel boyutundaki beyaz renkteki kutucuklardan ekrana yazdırmak isteği harfi-sembolü içeren kutucuğa odaklanmasıyla gerçekleşmiştir. Belirlenen frekanslar 60 Hz olan ekran tazeleme oranımızla uyumluluğu gözönünde tutularak seçilmiştir [40, 96]. Deneyin yazdırmak istediği kelimenin ne kadarının yazdırabildiğini ekrandan görmekte, dolayısıyla sırada hangi harfin yazdırılması gerektiğini tespit edebilmektedir. Denek ilk SSVEP çalışmamızda olduğu gibi yine simülasyon ekranından yaklaşık olarak 50 cm uzağa oturtulmuş, deney sırasındaki beyin aktivitesi 8 altın elektrot ile 500 Hz örnekleme frekansıyla toplanmış ve sinyal toplama da BioRadio (Great Lakes NeuroTechnologies, USA) sinyal yükseltici kullanılmıştır. Uluslararası 10-20 sistemine göre belirlenen elektrot yerleşim biçimi Şekil 4.30 ile verilmiştir.

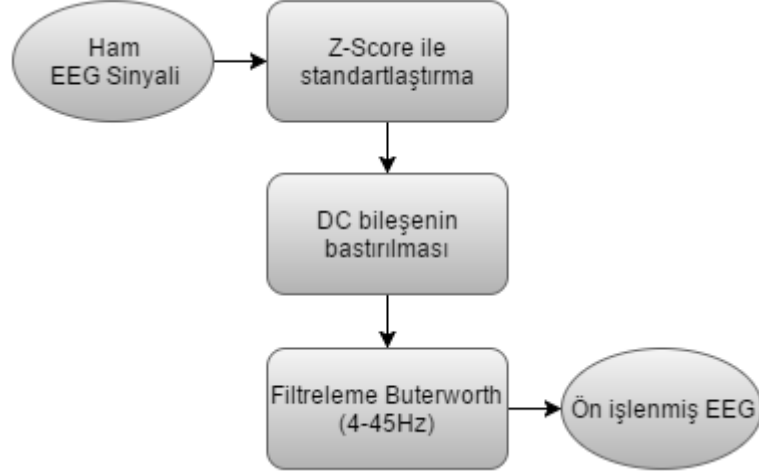


Şekil 4.30. Türkçe temelli beyin bilgisayar yazıcısı elektrot yerleşimi.

BBA sistemi MATLAB 2105a ortamına geliştirilmiş, kullanıcı arayüzü için Psychtoolbox kütüphanesinden faydalanılmıştır. Grafikselleştirme arayüzünün tasarımında kullanılan 6 adet 100 x 100 pixel boyutundaki kutu, içerisinde barındıracağı sembol ihtimalleri ile beraber siyah beyaz grafik formatında oluşturulmuş, bu grafikselleştirme yapıları da 1 ve 0 lardan oluşan matris formuna dönüştürülmüştür. BBA sistemini aracılığıyla, kullanıcıya, bu 1 ve 0 lardan oluşan matris formatındaki ekranlar ilgili frekanslarda gösterilmiştir.

4.4.2. Sinyal Önleme

Verilerin standartizasyonu için z-skor yönteminden faydalanılmıştır. Toplam 8 kanaldan alınan 500 Hz örnekleme frekansına sahip EEG sinyalleri, 4-45 Hz arası band geçiren Butterworth tipi bir filter ile filtrelenmiştir. Filtreleme öncesi sinyalin doğru akım bileşeni bastırılmıştır. BBA yazıcısının sinyal önleme adımlarına ilişkin akış diyagramı Şekil 4.31 ile verilmiştir.



Şekil 4.31. Beyin bilgisayar yazıcısı sinyal ön işleme adımları.

4.4.3. Sinyal İşleme

Sinyal işlemede MEC yöntemi kullanılmıştır. MEC ile kutulara atanan 6 farklı frekans ve bu frekanslara ait ilk 5 harmonik bileşeni giriş sinyalinden çıkarılmış, kalan sinyali minimum seviyede bastırarak sinyal tespit edilmiş ve tespit edilen bastırma sinyali giriş sinyaline uygulanmıştır. MEC yöntemi ile kullanıcının titreşen kutulardan hangisine yoğunlaştığı tespit edilmiş ve sonuç ekrana yazdırılmıştır.

4.4.4. Sistem Performansının Değerlendirilmesi

Sistem performansının değerlendirilmesinde tekrarlanan deneylerdeki doğruluk ve buna bağlı olarak değişen bilgi transfer hızı hesaplanmıştır.

4.4.5. Deneysel Sonuçlar ve Değerlendirme

Senkron olarak gerçekleştirilen deneyler ana dili Türkçe olan üç denek ile gerçekleştirilmiştir. Deneylerde deneklerden ‘ANNE’, ‘BABA’ ve İngilizcedeki ‘HELLO’ kelimelerini sadece ekranda titreşen kutulara bakarak yazmaları istenmiştir. Deneklerin farklı sinyal pencere uzunluklarındaki başarıları hesaplanmış bu veriler Çizelge 4.20, Çizelge 4.21, Çizelge 4.22 ve Çizelge 4.23 ile verilmiştir.

Çizelge 4.20. 5 sn Sinyal pencere genişliği deney sonuçları.

Denek	Anne			Baba			Hello		
	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)
S1	8	0	31,02	8	0	31,02	10	0	31,02
S2	8	0	31,02	8	0	31,02	10	0	31,02
S3	11	1	24,02	8	0	31,02	10	0	31,02

Çizelge 4.21. 4 sn Sinyal pencere genişliği deney sonuçları.

Denek	Anne			Baba			Hello		
	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)
S1	8	0	38,77	8	0	38,77	10	0	38,77
S2	8	0	38,77	8	0	38,77	10	0	38,77
S3	10	2	23,19	11	1	30,02	11	1	30,02

Çizelge 4.22. 3 sn Sinyal pencere genişliği deney sonuçları.

Denek	Anne			Baba			Hello		
	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)
S1	8	0	51,70	8	0	51,70	10	0	51,70
S2	8	0	51,70	8	0	51,70	10	0	51,70
S3	11	1	40,03	8	0	51,70	11	1	40,03

Çizelge 4.23. 2 sn Sinyal pencere genişliği deney sonuçları.

Denek	Anne			Baba			Hello		
	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)	Doğru	Yanlış	ITR (bit/dk)
S1	11	1	60,04	10	2	46,38	10	0	77,55
S2	8	2	41,32	8	2	41,32	11	1	60,04
S3	11	1	60,04	10	2	46,38	12	2	50,12

Sonuçlar sinyal pencere genişliği artarken yüksek ITR değerleri yakalansa bile istikrarlı bir doğruluğun devamlı olmadığı yönündedir. En yüksek ITR değeri 77.55 bit/dk olarak denek 1 ile sinyal pencere genişliği 2 sn seçilerek elde edilmiştir. Ancak denek1 ve denek 2 sinyal pencere genişlikleri 5, 4, 3 sn seçildiğinde de tekrarlanan deneylerde verilen tüm kelimeleri hatasız yazdırmayı başarmışlardır. 3sn lik pencere genişliğinin tasarlanan sistem için en uygun pencere genişliğine denk geldiği, ayrıca kullanıcının sisteme hâkimiyeti açısından konforlu bir kullanım sunduğu belirlenmiştir. Önceki SSVEP tabanlı çalışmalarımızda gözlemlenen, sakin deneklerdeki başarı, stresli yapıdaki deneklerde karşılaşılan olumsuzluklar bu çalışmamızda da gözlemlenmiştir. Çizelge 4.24 ile güncel SSVEP tabanlı çalışma örnekleri ve performansları verilmiştir. Çalışmalarda her ne kadar yalnızca yüzde olarak verilen sistem doğruluğu belirtilmişse de ITR değerleri gerçek sistem performansını temsil eder.

Çizelge 4.24. SSVEP tabanlı çalışma örnekleri.

Sinyal Pencere Genişliği (ms)	Çalışma Adı	Yıl	Yöntem	Doğruluk %	ITR (bit/dk)
1000	Multiway Canonical Correlation Analysis for Frequency Components Recognition in SSVEP-based BCIs	2011	CCA	85,3	38,7
1000	Application of a reconstruction technique in detection of dominant SSVEP frequency	2018	CCA	>50	-
5000	An SSVEP Based BCI to Control a Humanoid Robot by Using Portable	2013	FFT	75	-
914	SSVEP based Bremen-BCI boosting information transfer rates	2011	CCA	78,96	124
812,5 - 16,250	Age-related differences in SSVEP-based BCI performance	2016	MEC	99,22	36,66
1500	The extension of multivariate synchronization index method for SSVEP-based BCI	2017	MSI	-	44,18
5000	Control of a humanoid robot by a noninvasive brain-computer interface in humans	2008	LIBSVM	95	-

BÖLÜM 5

GENEL SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında BBA sistemlerinde performans artırma ve iyileştirmelere yönelik geliştirilen yaklaşımlar ile özgün BBA tasarımları sunulmuştur;

Bu doğrultuda öncelikle MI tabanlı BBA sistemlerinde optimum kanal setinin belirlenmesine yönelik özgün bir yaklaşım olan ADA algoritması geliştirilmiş, algoritma hazır MI veri setleriyle (BCI Competiton III-Ia ve BCI Competition IV-3) başarıyla test edilmiştir. BCI Competiton III-Ia veri seti algoritma yardımıyla seçilen en uygun kanal kümesi ve sınıflandırma özellikleri ile sınıflandırmaya tabii tutulmuş ve literatürde elde edilmiş tüm sınıflandırma başarılarının da üstünde bir sınıflandırma başarısı (% 95) elde edilmiştir. Önerilen algoritma özellikle çok kanallı MI tabanlı BBA sistemlerinde en verimli kanal setinin tespitini sağlamaktadır. Sınıflandırma basamağı geleneksel yaklaşımlardan farklı olarak, derin yapay sinir ağıyla da test edilerek %80 oranında bir sınıflandırma başarısı göstermiştir. Derin ağlar görüntü işleme çalışmalarında ağırlıklı olarak kullanılmaktadır. Bu açıdan sunulan bu sınıflandırma basamağı da derin ağların BBA sistemlerinde kullanılması açısından özgünlük göstermekte, kanal seçimi ve özellik çıkarımı basamaklarının derin ağın içinde otomatikleştirilmiş olmasıyla da tasarım kolaylığı sağlamaktadır.

Yine tez çalışması kapsamında hazır veri setlerinden özgün veri setlerine geçişte karşılaştığımız nörolojik veriyi olumsuz yönde etkilen göz artefaktlarının temizlenerek performans olumsuzluklarının giderilmesi amaçlanmış bu bağlamda FEAD ve EBR algoritmaları geliştirilmiştir. FEAD algoritması ile göz artefaktları tespit edilmekte, EBR algoritması ile tespit edilen göz artefaktı nörolojik bilgi içeren EEG sinyalinden çıkarılarak sinyal temizlenmektedir. Tümüyle otomatik çalışan ICA ve DWT tabanlı EBR algoritması ile sisteme istenilen formatta verilen EEG seti sistem çıkışında göz artefaktları temizlenmiş olarak alınmaktadır. Sistem özgün

olarak en az bozulmaya sahip, göz artifaktı içermeyen çıkış sinyaline odaklanarak kırılacak ICA bileşen setini belirlemekte ve seçilen ICA bileşen setinde kırpma gerçekleştirmektedir. Sistem üç deneğe ait her biri 240 denemeden oluşan toplam 720 adet deneme içeren özgün veri setleriyle test edilmiş ve oldukça başarılı sonuçlar elde edilmiştir.

BBA sistemlerinde performansı etkilenen bir diğer etken tasarımıdır. Bu bağlamda tez kapsamında SSVEP tabanlı iki adet BBA sistemi tasarlanmıştır. Bu tasarımlardan ilki ile dört farklı yöne hareket edebilen bir robot kontrolü sağlanırken, ikinci tasarımla istenilen harf ve sembollerin sadece deneğe ait bir bilgisayar ekranından uyarılan beyin sinyalleri kullanılarak, yine bilgisayar ekranına yazdırılması gerçekleştirilmiştir. SSVEP tabanlı robot kontrol tasarımında FEAD algoritması ile yakalanan göz kırpma sayıları ile sistem aktivasyonu sağlanarak sistem kullanılabilirliği artırılmıştır. Bu sayede kullanıcı istediği anda sistemi açıp kapayabilmektedir. Speller tasarımı her biri 6 adet sembol veya harf içeren 6 hedefe sahiptir. Bünyesinde barındırdığı Türkçe ve Latin harfler yardımıyla hem Türkçe hem de Latince kelimeleri deneğe ait EEG sinyallerini analiz ederek bilgisayar ekranına kolayca yazabilmektedir. Tasarım bir harfin ekrana yazdırılması için iki seçime ihtiyaç duymaktadır. Bu açıdan literatürde karşılaştığımız üç ve daha fazla seçime sahip tasarımlara göre avantaj ve kullanım kolaylığı sağlamaktadır. Robot kontrol tasarımında uyarım ve sinyal işleme iki ayrı bilgisayara atanmışken, ikinci tasarımda bu işlemler tek bir taşınabilir bilgisayar ile yapılmıştır. SSVEP tabanlı BBA tasarımlarıyla sırasıyla oldukça iyi sayılabilecek ITR oranları 133 bit/dk 0,9s sinyal pencere uzunluğu ve 77,55 bit/dk 2 s sinyal pencere uzunluğu ile yakalanmıştır.

Önerilen SSVEP tabanlı tasarımlarda 8 kanallı BioRadio (Great Lakes NeuroTechnologies, USA) sinyal yükselteci kullanılmıştır. Deneylerde altın kaplı elektrotlar tercih edilmiştir.

SSVEP tasarımlarında karşılaştırmalı olarak test edilen MEC ve CCA yöntemlerinin yakın sonuçlar vermesine karşın, MEC yönteminin daha başarılı sonuçlar verdiği gözlemlenmiştir.

SSVEP tabanlı deneyler sırasında stres faktörünün deney sonuçlarını olumsuz etkilediği gözlemlenmiş, kişiye özel tasarımların daha başarılı sonuçlar verebileceği öngörülmüştür. Kişisel farklılıkların BBA sistemleri üzerindeki etkisi ve konuşma frekanslarının EEG sinyalleri üzerindeki yansımaları araştırılacak konular arasındadır.



KAYNAKLAR

1. Vidal, J. J., “Toward direct brain-computer communication” *Annual review of Biophysics and Bioengineering*, 2(1): 157-180 (1973).
2. Vidal, J. J., “Real-time detection of brain events in eeg” *Proceedings of the IEEE*, 65(5): 633–641, (1977).
3. Berger, H., “Über das elektroencephalogramm des menschen” *European Archives of Psychiatry and Clinical Neuroscience*, 87(1): 527–570, (1929).
4. Schalk, G. and Mellinger, J., “Human-Computer Interaction: Practical Guide to Brain-Computer Interfacing with Bci2000: General-Purpose Software for Brain-Computer Interface Research, Data Acquisition, Stimulus Presentation, and Brain Monitoring”, *Springer*, (2010).
5. Schalk, G., McFarland, D. J., Hinterberger, T. N., Birbaumer, and Wolpaw, J. R., “Bci2000: a general-purpose brain-computer interface (bci) system”, *Biomedical Engineering, IEEE Transactions*, 51(6): 1034–1043, (2004).
6. Delorme, A. and Makeig, S., “Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis”, *Journal of neuroscience methods*, 134(1): 9–21, (2004).
7. Dickhaus, H. and Heinrich, H., “Classifying biosignals with wavelet networks, a method for noninvasive diagnosis”, *IEEE Eng Med Biol Mag.*, 15: 103-111, (1999).
8. Wolpaw, J. R., Loeb, G. E., Allison, B. Z., Donchin, E., Nascimento, O. F., Heetderks, W. J., Nijboer, F., Shain, W. G. and Turner, J. N., “Bci meeting 2005 workshop on signals and recording methods”, *IEEE Transactions on neural systems and rehabilitation engineering*, 14: 138-141, (2006).
9. Huggins, J. E. and Zeitlin, D., “The ultimate practical goal of most braincomputer inter-faces (bcis) is to operate devices that provide communication”, *Brain-Computer Interfaces: Principles and Practice*, 197, (2012).
10. Beukelman, D. and Mirenda, P., “Augmentative and alternative communication”, (2005).
11. I. Fishman, *Electronic communication aids: Selection and use. College-Hill*, (1987).
12. Kübler, A., Holz, E., Kaufmann, T. and Zickler, C., “A user centred approach for bringing bci controlled applications to end-users”, (2013).

13. Walter Wg, Cooper R, Aldridge V.C., Winter, Mccallum & A.L., “Contingent Negative Variation: An Electric Sign Of Sensorimotor Association and Expectancy in The Human Brain”, *Nature*, 203: 380-384, (1964).
14. Bernat, E., Shevrin, H., Snodgrass, M., “Subliminal visual oddball stimuli evoke a P300 component”, *Clinical Neurophysiology*, 112(1): 159-171, (2001).
15. Gonsalvez, C.J. ve Polich, J., “P300 Amplitude is Determined by Target-To-Target interval”, *Psychophysiology*, 39: 388-396, (2002).
16. Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G. and Vaughan, T. M., “Brain–computer interfaces for communication and control”, *Clinical Neurophysiology*, 113: 767-791, (2002).
17. Farwell, L. A. and Donchin, E., ”Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials”, *Electroencephalogr. Clin. Neurophysiol.*, 70 (6): 510-523 (1988).
18. Akram, F., Han, H.S. and Kim, T.S., “A P300-based brain computer interface system for words typing”, *Computers in Biology and Medicine*, 45:118–125 (2014).
19. McFarland, D. J., Sarnacki, W. A., and Wolpaw, J. R., “Electroencephalographic (eeg) control of three-dimensional movement” *Journal of Neural Engineering*, 7(3): 036007, (2010).
20. İnternet: Educational materials, “<http://schoolbag.info/biology/humans/9.html>”, (2016).
21. Niedermeyer, E., “Niedermeyer’s Electroencephalography: basic principles, clinical applications and related fields, 4th ed.”, *Niedermeyer, E., Lopes da Silva F.H., Williams and Wilkins, Baltimore*, 149-173 (1999).
22. Pfurtscheller, G., “Handbook of Electroencephalography and Clinical Neurophysiology “, Lopes da Silva, F.H, *Elsevier*, Amsterdam, 6: 107-118 (1999).
23. Pfurtscheller, G., “Niedermeyer’s Electroencephalography: basic principles, clinical applications and related fields, 4th ed.”, Niedermeyer, E., Lopes da Silva, F.H., Williams and Wilkins, *Baltimore*, 958-967 (1999).
24. Pfurtscheller, G., Neuper, C., Flotzinger, D. and Pregenzer, M., “EEG-based discrimination between imagination of right and left hand movement”, *Electroenceph & Clinical Neurophysiology*, 103: 642-651 (1997).
25. Hill, N. and Schölkopf, B., “An online brain–computer interface based on shifting attention to concurrent streams of auditory stimuli”, *Journal of neural engineering*, 9(2): 026011, (2012).

26. Neumann, N. and Birbaumer, N., "Predictors of successful self control during brain-computer communication", *Journal of Neurology, Neurosurgery & Psychiatry*, 74(8): 1117-1121, (2003).
27. Neuper, C., Müller-Putz, G. R., Scherer, R. and Pfurtscheller, G., "Motor imagery and eeg-based control of spelling devices and neuroprostheses", *Progress in brain research*, 159: 393-409, (2006).
28. Kim, D. W., Hwang, H. J., Lim, J. H., Lee, Y. H., Jung, K. Y. and Im, C. H., "Classification of selective attention to auditory stimuli: toward vision-free braincomputer interfacing," *Journal of neuroscience methods*, 197(1): 180-185, (2011).
29. Riccio A, Mattia D, Simione L, Olivetti M, Cincotti F. "Eye-gaze independent EEG-based brain-computer interfaces for communication", *Journal of Neural Engineering*, 9:1-15, (2012).
30. Muller-Putz, G.R. ve Pfurtscheller, G., "Control of an Electrical Prosthesis With an SSVEP-Based BCI", *IEEE Transactions on Biomedical Engineering*, 55(1): 361-364, (2008).
31. Lee, P.L., Yeh, C.L., Cheng, J.Y.S., Yang, C.Y., Lan, G.Y., "An SSVEP-Based BCI Using High Duty-Cycle Visual Flicker", *IEEE Transactions on Biomedical Engineering*, 58(12): 3350-3359, (2011).
32. Sutter, E. E., "The visual evoked response as a communication channel", *Proceedings of the IEEE Symposium on Biosensors*, 95-100, (1984).
33. Sutter, E. E., "The brain response interface: communication through visually-induced electrical brain responses", *Journal of Microcomputer Applications*, 15(1): 31-45, (1992).
34. G. L. Calhoun, G. R. McMillan, P. E. Morton, M. S. Middendorf, J. H. Schnurer, D. F. Ingle, R. M. Glaser, ve S. F. Figoni, "Control of functional electrical stimulation with a direct brain interface", Proc. *RESNA '95*, 696-698, (1995).
35. Hwang, H. J., Lim, J. H., Jung, Y.J., Choi, H., Lee, S. W. and Im, C.H., "Development of an ssvpe-based bci spelling system adopting a qwerty style led keyboard", *Journal of neuroscience methods*, 208(1): 59-65, (2012).
36. Yin, E., Zhou, Z., Jiang, J., Chen, F., Liu, Y. and Hu, D., "A novel hybrid bci speller based on the incorporation of ssvpe into the p300 paradigm", *Journal of neural engineering*, 10(2): 026012, (2013).
37. Allison, B., Luth, T., Valbuena, D., Teymourian, A., Volosyak, I. and Graser, A., "Bci demographics: How many (and what kinds of) people can use an ssvpe bci?", *Neural Systems and Rehabilitation Engineering*, 18(2): 107-116, (2010).

38. Volosyak, I., Cecotti, H., Valbuena, D. and Graser, A., "Evaluation of the bremen ssvp based bci in real world conditions", *Rehabilitation Robotics*, 2009. ICORR 2009. **IEEE International Conference on. IEEE**, 322-331, (2009).
39. Friman, O., Luth, T., Volosyak, I. and Graser, A., "Spelling with steady-state visual evoked potentials", *Neural Engineering*, 2007. CNE'07. **3rd International IEEE/EMBS Conference**, 354-357, (2007).
40. Volosyak, I., Cecotti, H. and Gräser, A., "Impact of frequency selection on lcd screens for ssvp based brain-computer interfaces", *Bio-Inspired Systems: Computational and Ambient Intelligence. Springer*, 706-713, (2009).
41. McFarland, D. J. and Wolpaw. J. R., "Sensorimotor rhythm-based brain-computer interface (bci): feature selection by regression improves performance", **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, 13 (3): 372-379 (2005).
42. Penny, W. D., Roberts, S. J., Curran, E. A. and Stokes, M. J., "EEG-based communication: a pattern recognition approach", **IEEE Transactions on Rehabilitation Engineering**, 8 (2): 214-215 (2000).
43. Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F. and Arnaldi, B., "A review of classification algorithms for EEG-based brain-computer interfaces", **Journal Of Neural Engineering**, 4 (2): 1-13 (2007).
44. Duda, R. O., Hart, P. E. and Stork, D. G., "Pattern Recognition, Second Edition", **Wiley**, 3-5 (2001).
45. Donchin, E., Spencer, K. M. and Wijesinghe, R., "The mental prosthesis: assessing the speed of a p300-based brain-computer interface", *Rehabilitation Engineering*, **IEEE Transactions**, 8(2): 174-179, (2000).
46. Combaz, A., Chumerin, N. Manyakov, N. V., Robben, A., Suykens, J. A. and Van Hulle, M. M., "Error-related potential recorded by eeg in the context of a p300 mind speller brain-computer interface", **Machine Learning for Signal Processing (MLSP) International Workshop on. IEEE**, 65-70, (2010).
47. Blain-Moraes, S., Schaff, R., Gruis, K. L., Huggins, J. E. and Wren, P. A., "Barriers to and mediators of brain-computer interface user acceptance: focus group findings", **Ergonomics**, 55(5): 516-525, (2012).
48. Bianchi, L., Sami, S., Hillebrand, A., Fawcett, I. P., Quitadamo, L. R. and Seri, S., "Which physiological components are more suitable for visual erp based brain-computer interface? a preliminary meg/eeg study", **Brain topography**, 23(2): 180-185, (2010).
49. Rakotomamonjy, A., Guigue, V., Mallet, G., and Alvarado, V., "Ensemble of svms for improving brain computer interface p300 speller performances",

- Artificial Neural Networks: Biological Inspirations–ICANN 2005. *Springer*, 45-50, (2005).
50. Rakotomamonjy, A. and Guigue, V., “Bci competition iii: dataset ii-ensemble of svms for bci p300 speller,” *Biomedical Engineering, IEEE Transactions*, 55(3): 1147-1154, (2008).
 51. Bostanov, V., “Bci competition 2003-data sets ib and iib: feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram”, *Biomedical Engineering IEEE Transactions*, 51(6): 1057-1061, (2004).
 52. Combaz, A., Manyakov, N. V., Chumerin, N., Suykens, J. A. and Hulle, M., “Feature extraction and classification of eeg signals for rapid p300 mind spelling”, *Machine Learning and Applications ICMLA’09*, 386-391, (2009).
 53. Krusienski, D. J., Sellers, E. W., Cabestaing, F., Bayouhd, S., McFarland, D. J., Vaughan, T. M. and Wolpaw, J. R., “A comparison of classification techniques for the p300 speller”, *Journal of neural engineering*, 3(4): 299, (2006).
 54. Combaz, A., Chumerin, N., Manyakov, N. V., Robben, A., Suykens, J. A. and Van Hulle, M. M., “Towards the detection of error-related potentials and its integration in the context of a p300 speller brain–computer interface,” *Neurocomputing*, 80: 73-82, (2012).
 55. Serby, H., Yom-Tov, E. and Inbar, G., “An improved P300-based brain computer interface”, *Neural Systems and Rehabilitation Engineering IEEE Transactions*, 13(1): 89-98, (2005).
 56. Marchetti, M., Piccione, F., Silvoni, S., Gamberini, L. and Priftis, K., “Covert visuospatial attention orienting in a brain-computer interface for amyotrophic lateral sclerosis patients”, *Neurorehabilitation and neural repair*, 27(5): 430-438, (2013).
 57. Piccione, F., Giorgi, F., Tonin, P., Priftis, K., Giove, S., Silvoni, S., Palmas, G. and Beverina, F., “P300-based brain computer interface: reliability and performance in healthy and paralysed participants”, *Clinical neurophysiology*, 117(3): 531-537, (2006).
 58. Thulasidas, M., Guan, C. and Wu, J., “Robust classification of eeg signal for brain-computer interface”, *Neural Systems and Rehabilitation Engineering IEEE Transactions*, 14(1): 24-29, (2006).
 59. Orhan, U., Erdogmus, D., Roark, B., Oken, B. and Fried-Oken, M., “Offline analysis of context contribution to erp-based typing bci performance”, *Journal of neural engineering*, 10(6): 066003, 2013.

60. Krusienski, D., Sellers, E., McFarland, D., Vaughan, T. and Wolpaw, J., "Toward enhanced P300 speller performance", *Journal of neuroscience methods*, 167(1): 15-21, (2008).
61. Li, Y., Guan, C., Li, H. and Chin, Z., "A self-training semi-supervised svm algorithm and its application in an eeg-based brain computer interface speller system", *Pattern Recognition Letters*, 29(9): 1285-1294, (2008).
62. An, X., Wan, B., Qi, H. and Ming, D., "Digital spelling bci based on visualauditory associate stimulation", *Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS) 2012 IEEE*, 82-85, (2012).
63. Millan, J. del R., Mourĩno, J., Franz'e, M., Cincotti, F., Varsta, M., Heikkonen, J. and Babiloni, F., "A local neural classifier for the recognition of eeg patterns associated to mental tasks", *Neural Networks*, 13(3): 678-686, (2002).
64. Millan, J., Mourĩno J., "Asynchronous bci and local neural classifiers: an overview of the adaptive brain interface project", *Neural Systems and Rehabilitation Engineering*, 11(2): 159-161, (2003).
65. Marchetti, M., Onorati, F., Matteucci, M., Mainardi, L., Piccione, F., Silvoni, S. and Priftis, K., "Improving the efficacy of erp-based bcis using different modalities of covert visuospatial attention and a genetic algorithm-based classifier", *PLoS one*, 8(1): e53946, (2013).
66. Paraschiv-Ionescu, A., Jutten, C., Aminian, K., Naja, B. and Robert, P., "Wavelet denoising for highly noisy source separation", *Circuits and Systems ISCAS IEEE International Symposium*, (2002).
67. Hyvärinen, A., and Oja, E., "Independent Component Analysis: Algorithms and Applications", *Neural Networks*, 13(4-5): 411-430, (1999).
68. Stone, J. V., "Independent component analysis: anintroduction," *TRENDS in Cognitive Sciences*, 6(2): 59-64, (2002).
69. Behera, S. K., "FastICA for Blind Source Separation and Its Implementation," *National Institute of Technology Rourkela - Department of Electronics and Communication Engineering*, (2009).
70. Taha, A. L., "FPGA Implementation of Blind Source Separation using FastICA," *The University of Windsor - Department of Electrical and Computer Engineering*, (2010).
71. Mensh B. D., Werfel J. and Seung H. S., "BCI Competition 2003—Data Set Ia: Combining Gamma-Band Power With Slow Cortical Potentials to Improve Single-Trial Classification of Electroencephalographic Signals", *IEEE Transactions on biomedical engineering*, 51(6): 1052-1055, (2004).

72. Wallraven C., Caputo B. and Graf A., "Recognition with local features: the kernel recipe.", In Proc. *ICCV*, 257-264, (2003).
73. Wolf L. and Shashua A., "Kernel principal angles for classification machines with applications to image sequence interpretation.", In Proc. *CVPR*, 1: 635-640, 2003.
74. Schüldt C., Laptev I. and Caputo B., "Recognizing Human Actions: A Local SVM Approach", In Proc. *CVPR*, (2004).
75. Gao, T. F. and Liu, C. L., "High accuracy hand written Chinese character recognition using LDA-based compound distances", *Pattern Recognition*, 41: 3442-3451, (2008).
76. Le, Q.V, et al., "Building High-Level Features Using Large Scale Unsupervised Learning", In *Proceedings of the 29th International Conference on Machine Learning*, Edinburgh, (2012).
77. Taigman, Y., et al., "DeepFace: Closing the Gap to Human-Level Performance in Face Verification", *Conference on Computer Vision and Pattern Recognition (CVPR)*, (2014).
78. Deng, L. and Yu, D., "Deep Learning: Methods and Applications", *Foundation and Trends in Signal Processing*, 7: 197-387, (2014).
79. Huang, G. B., Ramesh, M, Berg, T, and LearnedMiller, E., "Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments", *University of Massachusetts, Amherst*, Technical Report, 07-49, (2007).
80. Schroff, F., Kalenichenko, D. and Philbin, J., "FaceNet: A Unified Embedding for Face Recognition and Clustering.", *CVPR*, (2015).
81. Toth, L., "Phone Recognition with deep sparse rectifier neural networks", *ICASSP*, (2013).
82. Friman, O., Volosyak, I. and Graäser, A., "Multiple channel detection of steady state visual evoked potentials for brain-computer interfaces", *IEEE Trans. Biomed. Eng.*, 54: 742-750, (2007).
83. Volosyak, I., "Ssvpep based bremen-bci boosting information transfer rates", *Neural Eng.*, 8: 62-71, (2011).
84. Hotelling, H., "Relations between two sets of variates", *Biometrika*, 28, 321-377, (1936).
85. Wolpaw, J. R., Ramoser, H., McFarland, D. J. and Pfurtscheller, G., "Eeg based communication: improved accuracy by response verification", *IEEE Trans. Rehabil. Eng.*, 6: 326-333, (1998).

86. Lal T., Hinterberger T., Widman G., Schröder M., Hill J., Rosenstiel W., Elger C., Schölkopf B. and Birbaumer N. "Methods Towards Invasive Human Brain Computer Interfaces", *Advances in Neural Information Processing Systems (NIPS)*, (2004).
87. Gastaut H., "Etude electrocorticographique de la reactivite des rythmes rolandiques", *Revue Neurologique*, 87: 176-182, (1952).
88. Kreyszig, E. "Advanced Engineering Mathematics 9th", *John Wiley*, New York, 1017-1018, (2006).
89. Brigham, K. and Kumar, B., "Imagined speech classification with eeg signals for silent communication: a preliminary investigation into synthetic telepathy", *Bioinformatics and biomedical engineering (icbbe)* 4: 1-4, (2010).
90. DaSalla, C., Kambara, H., Sato, M., Koike, Y., "Single-trial classification of vowel speech imagery using common spatial patterns", *Neural Networks*, 22: 1334-1339, (2009).
91. Wester, M., Schultz, T., "Unspoken speech - speech recognition based on electroencephalography", masters thesis, *institut fr theoretische informatik universitt karlsruhe (th)*, karlsruhe, germany (2006).
92. Wang, L., Zhang, X., Zhong, X., and Zhang, Y., "Analysis and classification of speech imagery EEG for BCI", *Biomedical Signal Processing and Control*, 8: 901-908, (2013).
93. Vigon, L., Saatchi, M. R., Mayhew, J. E.W., and Fernandes, R., "Quantitative evaluation of techniques for ocular artefact filtering of EEG waveforms," *Sci. Meas. Tech., IEE Proc.*, 147(5): 219-228, (2000).
94. Kelly, J.W., Siewiorek, D.P., Smailagic, A., Collinger, J.L., Weber, D.J. and Wang, W. ,"Fully automated reduction of ocular artifacts in high-dimensional neuraldata", *IEEE Trans. Biomed. Eng.*, 58(3): 598-606 (2011).
95. Pastor, M. A., Artieda, J., Arbizu, J., Valencia, M. and Masdeu, J., "Human cerebral activation during steady-state visual-evoked responses", *Neurosci*, 23: 1162111627, (2003).
96. Cecotti, H., Volosyak, I. and Graser, A., "Reliable visual stimuli on lcd screens for ssvep based bci", *European Signal Processing Conference (EUSIPCO)* 18, 919-923, (2010).
97. Lalor, E. C., Kelly, S. P., Finucane, C., Burke, R., Smith, R., Reilly, R. B. and McDarby, G., "Steady state vep-based brain-computer interface control in an immersive 3d gaming environment", *EURASIP*, 19: 3156-3164, (2005).

98. Gao, X., Xu, X., Cheng, M. and Gao, S., “A bci-based environmental controller for the motion-disabled”, *IEEE Trans. Neural Syst. Rehabil. Eng.* 11, 137-140, (2003).
99. Volosyak, I., “Ssvpep based bremen-bci boosting information transfer rates”, *Neural Eng.*, 8: 62-71, (2011).
100. Bin, G., Gao, X., Yan, Z., Hong, B. and Gao, S., “An online multi-channel ssvpep based brain-computer interface using a canonical correlation analysis method”, *Neural Eng.*, 6: 046002, (2009).
101. Volosyak, I., Gemblar, F. and Stawicki, P., “Age-related differences in ssvpep based bci performance”, *Neurocomputing*, 250: 57-64, (2017).
102. Zhang, Y., Guo, D., Yao, D. and Xu, P., “The extension of multivariate synchronization index method for ssvpep-based bci”, *Neurocomputing*, 269: 226-231, (2017).

ÖZGEÇMİŞ

Erdem ERKAN 1977 yılında Bartın'da doğdu; ilk ve orta öğrenimini aynı şehirde tamamladı. Bartın Lisesi Fen Bölümü'nden mezun oldu. 1995 yılında Dokuz Eylül Üniversitesi Bilgisayar Programcılığı Bölümüne başlayıp 1997 yılında mezun oldu. 2 Yıl süren ilk çalışma deneyiminden sonra tekrar 1999 yılında Niğde Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde öğrenimine başlayıp 2003 yılında iyi derece ile mezun oldu. 2005 yılında Niğde Koyunlu Halı Fabrikasında sistem analisti olarak göreve başladı. 2010-2011 yılları arasında Niğde Üniversitesi Bilgi İşlem Servisinde yazılım uzmanı olarak görev yaptı. 2011 yılında Bartın Üniversitesi Uzaktan Eğitim ve Araştırma Merkezinde yazılım uzmanı olarak göreve başladı. 2011-2013 yılları arasında yüksek lisans eğitimini Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda tamamladı. Halen Bartın da ikamet etmektedir.

ADRES BİLGİLERİ

Adres : Karaköy Mah.
Kadioğlu Sok. 59/1 Durukent Sit. B-16
Merkez / BARTIN
Tel : (542) 412 9967
E-posta : erdem__erkan@hotmail.com