



**HİBRİT (EEG- NIRS) BEYİN BİLGİSAYAR
ARAYÜZÜ SİSTEMLERİNDE SINIFLANDIRICI
PERFORMANSININ İYİLEŞTİRİLMESİ**

Abdulkerim ALMALI

Yüksek Lisans Tezi

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Yaşar DAŞDEMİR

2023

Her hakkı saklıdır.



FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ

HİBRİT (EEG VE NIRS) BEYİN BİLGİSAYAR ARAYÜZÜ SİSTEMLERİNDE
SINIFLANDIRICI PERFORMANSININ İYİLEŞTİRİLMESİ

Abdulkerim ALMALI

Tez Danışmanı: Dr. Öğr. Üyesi Yaşar DAŞDEMİR

Anabilim Dalı: Biyomedikal Mühendisliği

Erzurum

2023

Her hakkı saklıdır

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

05 / 07 / 2023

Abdulkerim ALMALI

ÖZET

YÜKSEK LİSANS TEZİ

HİBRİT (EEG-NIRS) BEYİN BİLGİSAYAR ARAYÜZÜ SİSTEMLERİNDE SINIFLANDIRICI PERFORMANSININ İYİLEŞTİRİLMESİ

Abdulkerim ALMALI

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Yaşar DAŞDEMİR

Beyin Bilgisayar Arayüzü (BBA), kişinin beyinde gerçekleşen sinirsel aktiviteler sonucunda elde edilen sinyallerin bir bilgisayar sistemi kullanılarak komut olarak işlenmesini sağlayan sistemdir. Temsili beyin sinyallerini görüntüleme sistemlerinin başında EEG ve NIRS gelmektedir. Hibrit sistemler tek taraflı sistemlerin sınırlamalarını aşmak ve sınıflandırıcının doğruluğunu arttırmak için kullanılır. Yaptığımız bu çalışmada kullanımı açık olan bir veri seti üzerinde öznitelik çıkarımlar yapıldıktan sonra Çoklu Örnek Öğrenimi yöntemi uygulanmış ve çeşitli sınıflandırıcıların performansları ölçülmüştür. Öznitelik çıkarımı işlemleri zaman etki alanı ile frekans etki alanında yapılmıştır. Sınıflandırıcı olarak en çok bilinen sınıflandırma algoritmaları olan Naive Bayes, Rastgele Ormanlar, k-En Yakın Komşu, Doğrusal Ayırtaç Analizi ve Destek Vektör Makineleri kullanılmıştır. Öznitelik seviyesinde yapılan füzyon işlemi performansı olumlu yönde etkilemiştir. EEG-DEOXY hibrit sisteminden elde edilen ikili sınıflandırma başarımı k-En Yakın Komşu algoritması ile 0.985 doğruluk olarak elde edilmiştir. Çoklu Örnek Öğrenimi algoritması sınıflandırma performanslarını olumlu yönde etkilemiştir.

2023, 43 Sayfa

Anahtar Kelimeler: Beyin-Bilgisayar Arayüzü, NIRS, EEG, Çoklu Örnek Öğrenimi

ABSTRACT

MS. Thesis

IMPROVING CLASSIFICATION PERFORMANCE IN HYBRID (EEG-NIRS) BRAIN-COMPUTER INTERFACE SYSTEMS

Abdulkerim ALMALI

Erzurum Technical University

Graduate School of Natural and Applied Sciences

Department of Biomedical Engineering

Supervisor: Assist. Prof. Dr. Yaşar DAŞDEMİR

A brain-Computer Interface (BCI) is a system that enables the signals obtained from neural activities in a person's brain to be processed as commands using a computer system. EEG and NIRS are the primary imaging systems for representative brain signals. Hybrid systems are used to overcome the limitations of one-sided systems and increase the accuracy of the classifier. In this study, after feature extractions were made on a data set that is open to use, the Multiple Instance Learning method was applied, and the performances of various classifiers were measured. Feature extraction operations were performed in the time domain and frequency domain. Naive Bayes, Random Forests, k-Nearest Neighbor, Linear Discriminant Analysis, and Support Vector Machines, the most well-known classification algorithms, are classifiers. The fusion at the attribute level positively affected the performance. The binary classification performance obtained from the EEG-DEOXY hybrid system was 0.985 with the k-Nearest Neighbor algorithm. The Multiple-Instance Learning algorithms positively affected the classification performances.

2023, 43 page

Keywords: Brain-Computer Interface, NIRS, EEG, Multiple Instance Learning,

TEŞEKKÜR

Bu tezi hazırlamamda her daim bilgi birikimi ile yanımda olan değerli danışman hocam Dr. Öğr. Üyesi Yaşar DAŞDEMİR'e ve her zaman desteklerini esirgemeyen sevgili eşim ve çocuklarıma teşekkürü bir borç bilirim.

Abdulkerim ALMALI
Temmuz 2023



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	12
3. MATERYAL ve YÖNTEM	16
3.1. Materyal	17
3.2. Yöntem.....	21
3.2.1. Önişleme adımları	21
3.2.2. Öznitelik çıkarım yöntemleri	22
3.2.3. Öznitelik füzyonu.....	25
3.2.4. Sınıflandırma yöntemleri	26
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	30
5. SONUÇ ve ÖNERİLER	35
KAYNAKLAR	42

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
ANN	Artificial Neural Networks
BBA	Beyin Bilgisayar Arayüzü
CNN	Convolutional Neural Network
CSP	Common Spatial Pattern
DBN	Deep Belief Networks
DWT	Discrete Wavelet Transform
EMD	Empirical Mode Decomposition
GELM	Graph regularized Extreme Learning Machine
HMM	Hidden Markov Model
ICA	Independent Component Analysis
KNN	<i>k</i> -Nearest Neighbour
LDA	Linear Discriminant Analysis
NB	Naive Bayes
NLPCA	Non-linear Principal Component Analysis
PCA	Principal Component Analysis
QDA	Quadratic Discriminant Analysis.
RF	Random Forest
STFT	Short-time Fourier Transform
SVM	Support Vector Machine
VAE	Variational Autoencoder
WPD	Wavelet Packet Decomposition
YKS	Yakın Kızılötesi Spektroskopi

ŞEKİLLER DİZİNİ

Şekil 1.1. Beyin bölgelerinin gösterimi	2
Şekil 1.2. Temsili BBA sistemi.....	3
Şekil 1.3. Örnek P300 sinyali	5
Şekil 1.4. DDGUPD-BBA için örnek paradigma ekranı	6
Şekil 1.5. WoS tarama sonucu	6
Şekil 1.6. EEG cihazı	7
Şekil 1.7. Örnek beyin dalgaları gösterimi	10
Şekil 1.8. YKS örnek çizimi	10
Şekil 3.1. Çalışmamızın akış diyagramı	16
Şekil 3.2. EEG (Yeşil) ve YKS (Kırmızı) elektrotları konumları.....	17
Şekil 3.3. Deneysel prosedür	19
Şekil 3.4. Multi instance learning	24
Şekil 3.5. Random forest.....	27
Şekil 3.6. KNN algoritması.....	28
Şekil 3.7. SVM temsili gösterimi.....	28
Şekil 4.1. EEG-OXY hibrit karmaşıklık matrisleri.....	33
Şekil 4. 2 EEG-DEOXY hibrit karmaşıklık matrisleri	34
Şekil 5.1. Zaman etki alanında sınıflayıcı performansları	35
Şekil 5.2 Frekans etki alanında sınıflandırıcı performansları	36
Şekil 5.3. Öznitelik düzeyinde füzyon işlemi sınıflandırıcı performansları a) EEG-OXY b) EEG-DEOXY	37

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 1.1. Beyin dalgaları ve frekans aralıkları.....	8
Çizelge 3.1. EEG lokasyonları.....	18
Çizelge 3.2. NIRS lokasyonları	20
Çizelge 3.3. Kullanılan sınıflandırıcıların parametreleri	29
Çizelge 4.1. Zaman domen sınıflandırıcı performansları	30
Çizelge 4.2. Frekans domen sınıflandırıcı performansları.....	31
Çizelge 4.3. CCA uygulanmış hibrit model sınıflandırıcı performansları.....	32
Çizelge 5.1. Yapılan Çalışmamız ile Literatürde Yapılan Diğer Çalışmalar.....	38
Çizelge 5.2. Yapılan çalışmamız ile literatürde yapılan diğer çalışmalar.....	39

1. GİRİŞ

İnsan beyni henüz tam olarak işleyişi çözümlenememiş esrarengiz yapısı ile araştırmacıların ilgi odağı olan bir organımızdır. Günümüzde tıptan mühendisliğe, eğitimden spora kadar birçok alanda beyin ile ilgili araştırmalar yapılmaktadır.

İnsan beyni kraniyal sinirler ve omurilik sayesinde merkezi sinir sistemini kontrol etmektedir. Beyin ayrıca çevresel sinir sistemini yönetirken, hemen hemen insanın tüm işlevlerini yapmasını sağlar. İnsan beyni yaklaşık olarak 1,5 kg ağırlığında ve kişiden kişiye değişmekle birlikte 1.130 ile 1.260 cm³ hacme sahiptir. Yaklaşık olarak insan beyninde 86 milyar nöron bulunmaktadır (Şekil 1.1.).

İnsan beyni kalp atışı, solunum ve sindirim gibi istemsiz eylemleri otonom sinir sistemi yardımı ile farkına varılmadan yönetir. Düşünce, mantık ve soyutlama gibi daha karmaşık zihinsel aktiviteler ise beyin tarafından bilinçli olarak yönetilir. Beynin bazı işlevleri şunlardır:


- Duyu organlarından sinirler yardımıyla gelen sinyalleri değerlendirmek.
- Problem veya olaylar hakkında çözümlemeler yapmak.
- Öğrenme faaliyetlerini ve hafızayı organize eder.
- Vücudun ihtiyaçlarını düzenler.
- Tansiyon ve vücut sıcaklığını ayarlar
- Vücudun hormonal durumunu düzenler

İnsan beyni beş ana lobdan oluşmaktadır. Bunlar:

1. Frontal Lob: Beynin ön tarafında bulunan, bilinçli düşünmeden sorumlu beyin bölgesidir. Frontal korteks insan beyninin 1/3'ünü oluşturmaktadır. Frontal korteksin arka kısmı yani motor korteks ve premotor korteks motor kontrolden sorumludur. Ayrıca prefrontal korteks olarak adlandırılan ön bölge ise davranış kontrolünde önemli rol oynamaktadır.
2. Parietal Lob: İnsan beyninin yön belirleme, acı, dokunma hisleri ve tatları algılama gibi işlevlerinin yerine getirildiği bölümdür. Eklem ve kaslardaki bilgilerin işlenmesi de görevleri arasındadır. Bir diğer adı *yan lob* olan bu kısmın hasar görmesi

durumunda; yüz tanımda zorluklar, nesnelerin konumunu belirleme ile nesnelerin kavranmasında zorluk ve algılama bozuklukları durumları yaşanır. Parietal lobu hasar görmüş kişilerde Alzheimer hastalığının görülme riski daha fazladır.

3. Oksipital Lob: Memelilerin beyinin serabral korteksini oluşturan dört lobdan biridir. Oksipital lob görsel algıdan sorumlu anatomik bölge olan görsel korteksin çoğunluğunu içerir. İşlevi retinadan gelen uyarıları algılamak ve yorumlamaktır.
4. Temporal Lob: Beynin yan tarafında yerleşimli telensefalon olarak adlandırılan bölgedir. Konuşma, hafıza ve işitmenin de olduğu birçok işlevi bulunmaktadır.
5. Serebellum: Diğer adı beyinciktir ve vücudun denge organlarından biridir. Beynin ikinci büyük parçasıdır ve beynin 1/8'i kadar büyüklüğe sahiptir. Beyincik, hemisferium cerebelli denilen iki yan lobla bunları ortada birleştiren vermis cerebelli'den oluşur. Beyincik kol ve bacaklardaki kasların birbiri ile uyumlu çalışması ve aktif hareketin dengeli olması işlevlerini yürütür.



Şekil 1.1. Beyin bölgelerinin gösterimi


İnsanlar teknolojik cihazları daha çok kas gücü ile kullanmaktadırlar. Telefon, televizyon ve bilgisayar gibi cihazlar kas gücü sayesinde kullanılmaktadır. Bunun yanında insanın ses komutları ile çalışan telefon, tablet veya ev uygulamaları ile insanın el, ayak ve yüz hareketlerini algılayarak çalışan video tabanlı uygulamalarda bulunmaktadır.

1. GİRİŞ

Elektromiyogram (EMG), elektroensefalogram (EEG) ve elektrookülogram (EOG) gibi elektronik kayıt sistemleri ile insandan alınan girdi verileri ile çalışan elektronik cihazlara “insan bilgisayar arayüzü (İBA)” denilmektedir. İBA sistemlerinin performansını sinyallerde bulunan gürültü doğrudan etkilemektedir. Tüm bu sinyal çeşitleri arasında en küçük gürültü oranına sahip olan mikro voltlar seviyesinde genliğe sahip olan EEG’dir.

Beyin-Bilgisayar Arayüzleri (BBA), etkileşimli bir uygulama için beyin aktivite modellerini mesajlara veya komutlara çevirebilen, bir bilgisayar sistemi kullanılarak komut olarak işlenmesini sağlayan sistemdir (Şekil 1.2.).

Beyin-bilgisayar ara yüzleri (BBA), bir kullanıcının niyetini nöral sinyallerinden çözmek için geliştirilmiştir (Bansal and Mahajan 2019). BBA sistemi bir kullanıcı, bilgisayar ve çevre birimlerinden oluşmaktadır. Kullanılan sistemde çevre birimi insan beyninden sinyalleri toplayıp çevrimi yaptıktan sonra bilgisayara ileten elemanlardan oluşmaktadır.



Şekil 1.2. Temsili BBA sistemi

1990’lı yıllarda ortaya çıkan BBA sistemleri ilk olarak ALS hastalığında olduğu gibi beyni sağlıklı fakat felçli hastaların yaşamlarını kolaylaştırmak için tasarlanmıştır. Fakat bu tür uygulamaların sağlıklı insanlar tarafından da kullanılabileceği anlaşılmıştır.

BBA'lar beynin nöral aktivitesini kayıt altına aldıktan sonra, yapay zekâ yardımı ile çözümler ve hangi komutun uygulanacağını tespit ederek elektronik cihazın düşünceler yardımı ile kontrol edilmesini sağlar. Bu sistemlerde beyin sinyallerinin kayıt edilmesi, sinyallere ön işlemenin uygulanması, öznitelik çıkarım işlemleri ve sınıflandırmanın yapılması olmak üzere dört alt işlem sırası mevcuttur.

Verinin kaydedilmesi adımı beyin nöral aktivitesi üç paradigma ile gerçekleştirilmektedir. Bu üç paradigma şunlardır:

1. Motor hayaline dayalı beyin bilgisayar arayüzleri


Motor hayali, herhangi bir fiziksel hareket olmadan kol veya ayak motor hareketinin yapıldığının hayal edilmesine dayanmaktadır (Lee et al. 2023). Yapılan araştırmalarda motor hareketin yapıldığının hayal edilmesi sırasında benzer nöral bağlantıların kullanıldığı ortaya çıkmıştır. Yüzde yüz benzemese de yapısında benzer örüntüler barındırdığı ve bu örüntülerin yapay zekâ algoritmaları ile işlenebileceği ortaya çıkmıştır. Bu tür sistemlere “motor hayaline dayalı beyin bilgisayar arayüzü (MHD-BBA)” denilmektedir. Tekerlekli sandalye, robot kol ve harekete dayalı bilgisayar oyunları gibi uygulamalar en çok karşılaşılan MHD-BBA uygulamalarıdır. Beyin sinyal örüntülerinin herkese göre farklılık göstermesi nedeniyle genel bir modelin üretilmemesi en büyük dezavantajıdır.

2. P300 sinyallerine dayalı beyin bilgisayar arayüzleri

İnsan beyni sinirlerden gelen sinyalleri işleyerek gerekli komutları verir. Duyu organlarından beklenmedik bir zamanda bir sinyal alındığında ise insan beyni yaklaşık 300 milisaniye sonra ilk tepkisini pozitif yönde sinyal değişikliği ile EEG sinyallerinde gösterir (Xiaolin et al. 2019). Literatürde bu durum uyarılmış potansiyeller veya P300 olarak isimlendirilir (Şekil 1.3.). Özellikle P300 tabanlı hecelemeye dayalı BBA'lar yüksek performans beklentisini karşılaması ve birçok avantajlarından dolayı çok sık kullanılmaktadır. Diğer bir önemli avantajı ise görsel uyarılmalarda beynin sadece oksipital bölgedeki nöral aktivitenin bilinmesinin uygulama için yeterli olacağının bilinmesidir. P300 tabanlı BBA'larda karşılaşılan önemli bir dezavantaj ise uyarımı

1. GİRİŞ


oluşturan paradigmanın zamanla tekrarlanmasından dolayı beynin tespit edilebilecek bir P300 sinyalini üretememesi ve sistem performansının düşmesidir.



Şekil 1.3. Örnek P300 sinyali


3. Durağan durum görsel uyarılmış potansiyellere dayalı beyin bilgisayar arayüzleri

İnsan beyninin öğrenilen bir diğer özelliği ise belirli bir frekansta olan uyaran serisinde oksipital bölgeden verilen tepkilerdir (Şekil 1.4.). Beynin bu tepki özelliğinden faydalanılarak oluşturulan beyin bilgisayar arayüzü sistemlerine Durağan Durum Görsel Uyarılmış Potansiyellere Dayalı Beyin Bilgisayar Arayüzleri adı verilmektedir. Şekildeki örnek incelendiğinde bu şekilde gösterilen yanıp sönen uyarıcılardan hangisine odaklanıldığında o frekansta oksipital bölgede nöral aktivite oluşmaktadır. Sınırlı sayıda komut hücresi oluşturulabilmesi bu sistemin en önemli dezavantajlarından biridir.



Şekil 1.4. DDGUPD-BBA için örnek paradigma ekranı

Beyin bilgisayar arayüzleri hakkında Web of Science (WoS) sitesinde yapılan brain computer interface ve brain machine interface kelimeleri ile literatür araması yapıldığında 19.901 sonuç elde edilmiştir. Bu çalışmaların disiplinlere göre dağılımı incelendiğinde en çok çalışmanın biyomedikal mühendisliği alanında yapıldığı anlaşılmaktadır (Şekil 1.5.). Bu grafikten de anlaşılabacağı üzere beyin bilgisayar arayüzleri hakkında en çok ilginin biyomedikal mühendisliğinde olduğu görülmektedir (Aydemir 2022).



Şekil 1.5. WoS tarama sonucu

WoS sonuçlarına göre beyin bilgisayar arayüzü hakkındaki ilginin arttığı ve bu teknoloji hakkında en çok çalışmaların Çin ve Amerika'da olduğu bilinmektedir. Sadece

1. GİRİŞ

engelli ve dezavantajlı bireylerin değil sağlıklı bireylerinde bu teknolojiyi kullanabilmesi için yazılımsal ve donanımsal çalışmalar devam etmektedir.

Elektroensefalografi (EEG), herhangi bir cerrahi müdahale olmadan, metal elektrotların kafanın belli bölgelerine yerleştirilmesiyle, beynin oluşturduğu sinyalleri görmeye yarar. Elektro fizyolojik dinamikler ekrana zikzaklar halinde yansır. Bu sinyaller bilişsel durum ve kişide bulunan hastalıklar hakkında bilgi verebilmektedir. Uyku halinde veya uyanıklık durumlarında farklı sinyaller görüntülenmektedir.

Elektroansefalografi 1900'lü yılların başında Hans BERGER isimli bilim insanı tarafından keşfedilmiştir. Elektrokimyasal sinyaller, sinirler arasında aktarılırken elektriksel alanlar meydana gelir. Bu sinyallerin milyonlarcası bir araya geldiğinde ise kafa tasının belirli konumlara yerleştirilen alıcılar sayesinde görüntülenebilecek büyüklüğe ulaşır. Hans Berger 20. yüzyılda beynin ürettiği bu elektriksel sinyalleri keşfetmiş; bu sinyallerin bazı bilişsel durumlarla ve hastalıklarla ilişkilendirmeye çalışmıştır. İlk klinik uygulama ise 1929 yılında bir hastanın EEG sinyallerinin kayıt edilmesi sayesinde olmuştur. Daha sonrasında ise Albert GRASS tarafından Harvard Tıp Okulu için 3 kanalı olan bir EEG cihazı geliştirilmiştir (Şekil 1.6.).



Şekil 1.6. EEG cihazı

EEG beyin anormalliklerinin tespiti ve analizi için BBA'da yaygın olarak kullanılmaktadır. EEG, doğası gereği yüksek zamansal çözünürlüğü ve kesinliği

1. GİRİŞ

açısından mükemmel olsa da anlık, doğrusal olmayan ve durağan olmayan doğası, düşük uzaysal çözünürlük ve özgüllük ile sonuçlanır.

EEG kayıtlarında temel olarak kayıt altına alınan sinyaller beynin sinirsel faaliyetleri sırasında oluşan 5 temel dalgadır (Çizelge 1.1.). Frekanslarına göre ayrılan bu 5 dalga şu şekilde isimlendirilir: delta, teta, alfa, beta ve gama. Delta dalgası 4 Hz. ve altı frekansa sahip sinyallerden oluşurken, Teta 4-7 Hz frekanslarındaki sinyallerden, Alfa dalgası 8-12 Hz arasındaki frekanslardan ve Beta dalgası ise 13 Hz ve daha üst frekanslardan oluşmaktadır (Şekil 1.7.).

Çizelge 1.1. Beyin dalgaları ve frekans aralıkları

TÜR	FREKANS (HZ)	YAPTIĞI İŞ
Delta	0,5-3,5 Hz	Yetişkin bireylerde, Uyku hali sırasında
Teta	4-7 Hz	Yetişkin bireylerde,
Alfa	8-12 Hz	Rahatlama durumlarında gözler kapalı iken
Beta	12-38 Hz	Uyarı alındığında, aktif düşünme, endişeli durumlarda, etkin konsantrasyon durumlarında
Beta (Orta)	15-21 Hz	Uyarı alındığında, aktif düşünme, endişeli durumlarda, etkin konsantrasyon durumlarında
Beta (Yüksek)	21-38 Hz	Stres ve anksiyete durumlarında
Gamma	34-100+ Hz	Belirli beyin işlevleri sırasında

Delta dalgaları yavaş ve en büyük genişliğe sahip dalga tipidir. Düşük frekanslı olmasına rağmen gürültü oranı çok yüksektir. Özellikle bebeklik yaşlarında ve diğer yaş gruplarında derin uyku sırasında görüntülenir. Özellikle kırklı yaşların ortalarında itibaren düşüş görülür. 75 yaşından sonra delta dalgalarının gözlemlenemez seviyede olduğu tespit edilmiştir.


Teta dalgaları, her yaşta, uyku halinde ve meditasyon sırasında görüntülenir. Yetişkinlerde uyanıklık durumlarında görüntülenmesi anormal durum olarak kabul edilir. Teta dalgaları delta dalgaları gibi yavaştır. Teta dalgalarının baskın olduğu zamanda genellikle kişi kendi iç dünyasına odaklanmıştır.

1. GİRİŞ

Alfa dalgaları, özellikle yetişkinlerde olmak üzere tüm yaş gruplarında görülür. Başın sağ ve sol taraflarından eşit şekilde yayılır. Gözlerin kapalı olduğu durumlarda, kafanın arka bölümlerinde görüntülenmesi beklenir. Alfa dalgalarının gözlerin açık olduğu durumlarda, stres halinde gözlemlenmesi beklenmez.

Beta dalgaları, tüm yaş gruplarında görülen bir beyin dalgasıdır. Genellikle simetrik ve başın ön bölümünde elde edilir. Normal uyanıklık sırasında en sık görülen paterndir. Kişi uyanık ve bir problemi çözmeye odaklanmışken veya yargılama, karar verme gibi süreçlerdeyken beta dalgaları baskındır.

Gama dalgaları en yüksek hıza sahip beyin dalgasıdır. Duygusal durumlarda aktif olarak gözlemlenir. Şizofreni gibi hastalıklarla ilişkili olduğu bilinmektedir.



Şekil 1.7. Örnek beyin dalgaları gösterimi


Yakın kızılötesi spektroskopisi (YKS-NIRS) doku hacmindeki ışık absorbesini oxyhemoglobin (OXY) ve deoxyhemoglobin (DEOXY) konsantrasyonlarındaki değişimlerle hesap ederek ölçen vasküler tabanlı fonksiyonel bir görüntüleme tekniğidir. YYS beynin bölgesel aktivasyonu ile ortaya çıkan Oksihemoglobin (HbO) ve Deoksihemoglobin (HbR) değişimine bağlı olarak serebral hemoglobinin

1. GİRİŞ

konsantrasyonlarını ölçebilen girişimsel olmayan fonksiyonel bir görüntüleme tekniğidir (Şekil 1.8.).

YKS, beyin dokusu oksijenlenmesini ve hemodinamisini gerçek zamanlı olarak ve hasta yatağı başında ölçebilen ve tıp doktorlarının önemli fizyolojik bilgilere erişmesine olanak tanıyan optik bir tekniktir. Bununla birlikte, YYS'nin klinik ortamda kullanımı zayıf tekrarlanabilirlik, derinlik duyarlılığı eksikliği ve zayıf beyin özgüllüğü gibi sınırlamalar nedeniyle engellenmektedir.

YKS, 600 ila 1.000 nm aralığındaki ışığın biyolojik dokunun derinliklerine nüfuz edebileceği gerçeğine dayanır, çünkü bu dalga boyu aralığında absorpsiyon düşüktür ve saçılma baskın etkileşim sürecidir. Ayrıca, kromofor adı verilen her soğurucunun kendine özgü bir soğurma veya sönme katsayısı vardır. Böylece her bir kromoforun katkısını ölçmek ve dokudaki konsantrasyonunu çözmek mümkündür. Oksijene bağımlı dokudaki ana kromoforlardan biri hemoglobindir; YYS, oksijenli (HbO_2) ve oksijensiz (HHb) hemoglobinin konsantrasyonlarını ölçebilir ve dolayısıyla doku oksijenlenmesini non-invaziv ve gerçek zamanlı olarak izleyebilir.



Şekil 1.8. YYS örnek çizimi (Pinti et al. 2020)

Metodolojik bir bakış açısından, bir YYS ölçümü üç farklı algılama modunda elde edilebilir: sürekli dalga (continuous wave - CW), frekans alanı (frequency domain-FD) ve zaman alanı (time domain-TD). Bu modlar, karmaşıklık seviyelerine ve alabilecekleri bilgi miktarına göre farklılık gösterir.

YKS hemodinamik değişiklikleri kılcal damar düzeyinde saptayabilmektedir. YKS korteksin yüzeysel katmanlarındaki oksijenli ve oksijensiz hemoglobin değişikliklerini ölçer. Oksihemoglobin, hemoglobinin oksijene bağlı şeklidir. Akciğerlerde solunum sırasında, kırmızı kan hücrelerinin hemoglobin bileşeni oksijene maruz kalır ve ona gevşek bir şekilde bağlanır. Oksijenin hemoglobine bağlanması, genellikle akciğerlerin içinde meydana gelen kanın yüksek pH, düşük karbondioksit ve yüksek sıcaklık koşullarında gerçekleşir. Sonuçta, oksihemoglobin tamamen doymuş formunda dört bağlı oksijen molekülü içerir. Bu nedenle, oksihemoglobinin, hemoglobinin gevşemiş durumunda olduğu kabul edilir. Deoksihemoglobin, oksijeni serbest bırakan hemoglobindir. Oksijen salınımı, düşük pH, yüksek karbondioksit konsantrasyonu ve düşük sıcaklık nedeniyle metabolize olan dokuda meydana gelir. Deoksihemoglobin, oksijen moleküllerinin salınması nedeniyle hemoglobinin gergin halidir. Oksihemoglobin ve deoksihemoglobin, oksijene bağlı evrelerine göre sınıflandırılan iki hemoglobin formudur.

Oksihemoglobin, 660 nm'de meydana gelen önemli ölçüde daha düşük bir absorpsiyona sahipken, deoksihemoglobin, 940 nm'de meydana gelen daha yüksek bir absorpsiyona sahiptir. Oksihemoglobin diyamanyetiktir, manyetik alan tarafından zayıf bir şekilde itilirken deoksihemoglobin, manyetik alan tarafından zayıf bir şekilde çekilen paramanyetiktir. Oksihemoglobin kalpten uzağa, deoksihemoglobin ise kalbe doğru taşınır.

BBA sistemlerinde sinyallerin işleme aşamalarından biri de sınıflandırma yapmak için kullanılacak sınıflandırıcının seçimidir. Birçok BBA sisteminde, sistemin başarımı sınıflandırma işleminin başarımı ile doğru orantılıdır. BBA sistemlerinde sınıflandırma yapmak için bir çok farklı algoritma kullanılmaktadır. Bunlardan bir kaç; Linear Discriminant Analysis (LDA), Multi Layer Perceptron (MLP), Support Vector Machine (SVM), Yapay Sinir Ağları (YSA), Karar Ağaçları gibi sıralanabilir.

2. KAYNAK ÖZETLERİ

Sınıflandırma performansının ölçüldüğü birçok çalışma olmakla beraber literatürde çoğunlukla tek taraflı sinyaller için sınıflandırıcı performanslarının ölçüldüğü çalışmalar mevcuttur. Hibrit (EEG-YKS) içeriğe sahip çalışmalar kısıtlı durumdadır. BBA'nın gelişmekte olan bir teknoloji olduğu ve beyin sırlarının tamamen çözülemediği düşünüldüğünde bu durum gayet normaldir.

Beyin bilgisayar arayüzü uygulamalarında Motor İmgeleme (Motor Imagery – MI) çalışmaları hala sınırlı düzeydedir. Bu durum için yapılan bir çalışmada sınıflandırma için Varyasyonel Otomatik Kodlayıcılı (VAE) Evrişimli Sinir Ağı (CNN) yapısı önerilmiştir. EEG sinyalinden alınan zaman, frekans ve kanal bilgileri birleştirilerek yeni bir girdi oluşturulmuş ve bu yeni girdi için CNN-VAE yöntemi optimize edilmiştir. CNN-VAE modelini kullanarak sınıflandırma doğruluğunu iyileştirme amaçlanmıştır (Dai et al. 2019). Bu çalışmada BCI Competition IV veri seti 2b için %3 daha iyi performans elde edilmiştir.

“EEG sinyallerinden duygu sınıflandırması yapılabilir mi?” sorusu Beyin Bilgisayar Arayüzleri için önemli bir çalışma alanı oluşturmaktadır. EEG sinyalleri tabanlı duygu sınıflandırma üzerine yapılan bir çalışmada iki duygusal kategoriye (pozitif ve negatif) sınıflandırmak için derin öğrenme yöntemleri denenmiştir. Bu çalışmada ilk olarak beta ve gama frekans bantlarındaki duygularla ilişkili sinyaller ile çalışılmış ve EEG verilerinden doğru ve kararlı bilgiler olduğu ortaya çıkarılmıştır. Ayrıca kNN, SVM ve GELM gibi sıkı modeller ile derin modeller arasında karşılaştırma yapılmıştır. Sonuç olarak Gama ve Beta frekans bantlarındaki salınımın diğer frekanslardaki salınımlardan daha iyi olduğu görülmüştür (Zheng et al. 2014).

Beyin bilgisayar arayüzlerinde başarımlı seçilen sınıflandırıcının performansı ile doğru orantılıdır. YKS üzerinde yapılan bir çalışmada iki mental görev (Mental aritmetik ve Rest) için altı sınıflandırıcının ortalama performansı karşılaştırması ve analizi yapılmıştır. Yedi katılımcı ile yapılan çalışmada beynin prefrontal korteks bölgesinden mental aritmetik ve dinlenme görevlerine ilişkin sinyaller elde edilmiş ve Linear Discriminant Analysis (LDA), Quadratic Discriminant Analysis (QDA), kNN, Naive

2. KAYNAK ÖZETLERİ

Bayes (NB), SVM ve Artificial Neural Networks (ANN) sınıflandırıcılarının performansları ölçülmüştür. Çalışmada ANN sınıflandırıcısı %91,4 ve %96,3 başarımları ile en iyi performansı vermiştir (Naseer et al. 2016).

YKS verileri ile Petrantonakis ve Kompatsiaris tarafından yapılan bir çalışmada sınıflandırıcı performansını arttırıcı başka bir yöntem olan GNIRS kullanılmıştır. Bu çalışmada LDA ve SVM sınıflandırıcıları kullanılmıştır. Mental aritmetik görevinin yapıldığı veri seti üzerinde sınıflandırıcılardan %92 başarımları elde edilmiştir (Petrantonakis and Kompatsiaris 2018).

YKS verilerinden farklı olay sınıflandırmaları için uygun özellik çıkarma ve sınıflandırma yöntemi bulmak önemlidir. YYS verilerinden BBA elde etmek için sınıflandırıcı seçimi ve öznelik çıkarımı iki ana adımdır. YYS sinyallerinin sınıflandırması hakkında yapılan başka bir çalışmada öncelikle Principal Component Analysis (PCA), Non-linear Principal Component Analysis (NLPCA), ve Independent Component Analysis (ICA) kullanılarak farklı istatistiksel öznelik çıkarımı yapılmıştır. Daha sonra ANN, kNN ve SVM sınıflandırma araçları kullanılarak sınıflandırma performansı ölçümü yapılmıştır (Kabir et al. 2018). Yapılan çalışmada çok yüksek başarımları elde edilmiştir.

Literatürde YYS tabanlı BBA çalışmaları sınıflandırma doğruluğunu arttıracak farklı yöntemler kullanılmıştır. YYS tabanlı motor hareket hayali çalışmalarından biri Naasar ve Hong'un çalışmalarıdır. Bu çalışmada, sağ-sol el bileği motor görüntü tabanlı YYS işaretlerinde LDA sınıflandırıcı ile HbO konsantrasyonundaki değişimin ortalaması ve eğimi öznelikleri kullanılarak ortalama sınıflandırma doğruluğu sırasıyla %77,56 ile %87,28 olarak elde etmişlerdir (Yin et al. 2015).

YKS verileri kaydedilirken birden fazla kanalın kullanımı önemli olmakla beraber verilerin çevrim dışı işlenmesi ve sınıflandırılması için uygun yöntemin bulunması ve bulunan bu yöntemin daha sonra Beyin Bilgisayar Arayüzleri için çevrim içi kullanımına sunmak gibi bir potansiyeli de bulunmaktadır. Sitaram ve arkadaşları, SVM ve Hidden Markov Modelini (HMM) kullanarak sağ ve sol ellerin parmakla hafifçe vurulması ve

gizlenmesine dayalı motor hareket hayali tabanlı YKS işaretlerini sırasıyla %73 ve %89'luk sınıflandırma doğruluğu ile hesaplamışlardır (Sitaram et al. 2007).

YKS tabanlı yüksek performanslı BBA oluşturmak ve yeni sinyal lokalizasyonu oluşturmak için yeni metotlar denenmiştir. İlgilenilen hemodinamik sinyalleri temsil etmek için çekirdek tabanlı bir model parametreleri tahmin ederek sinyalleri bulmak için matematiksel bir çözüm önerilebilir. Haiong ve Cuntai çalışmalarında sağ ve sol el motor hareketine dayalı YKS sinyallerine kernel temelli sinyal yerleştirme özneteliğini kullanmışlardır. Daha sonra SVM ile sınıflandırdıkları bu öznetelikten %74,10 sınıflandırma doğruluğu hesaplamışlardır (Haihong and Cuntai 2006).

Yapılan BBA çalışmaları çoklu sinyal kayıtlarının birbirinin dezavantajlarını telafi edeceği ve sistem performansını arttıracığı yönünde sonuçlar ortaya çıkarmıştır. Yavuz ve Aydemir, 2 sınıflı mental aritmetik tabanlı 29 kişiden kaydedilen EEG+YKS veri kümesi ile çalışarak sistem performansının arttırılmayı amaçlamıştır. Yapılan çalışmada Higuchi Fraktal boyutu ve özbağlanım metodu tabanlı öznetelikler çıkarılmıştır. Çıkarılan öznetelikler LDA, kNN, Naive Bayes, SVM, Decision Tree (DT), Random Forest (RF) gibi sınıflandırıcılar ile analiz edilmiştir. En iyi sınıflandırma performansı %94,08 ile LDA olmuştur. Ayrıca hibrit model EEG'ye göre %9,31 daha iyi sonuç vermiştir (Yavuz ve Aydemir 2020).

BBA'da her bir modalite ve her iki modalitenin bir kombinasyonu için sınıflandırma performansının değerlendirildiği temel sinyal analizi yöntemleri kullanılması hibrit çalışmaların da sınıflandırma performansını arttırabileceği sonucunu ortaya çıkarmıştır. Shin ve arkadaşları, 29 kişiden kayıt ettiği YKS tabanlı motor hareketine dayalı el -açma ve kapama işaretleri ile çalışmışlardır. Elde edilen YKS işaretlerini öncelikle 6. dereceden 0,1 ve 0,01 Hz'lik Butterworth filtresinden geçirmişlerdir. Filtrelenmiş olan sinyali öznetelik çıkarımı için ortak uzumsal örüntüleme tekniği ile elde etmişlerdir. Daha sonra çıkarmış oldukları öznetelik verisini LDA sınıflandırıcısı yöntemi ile sınıflandırmışlar ve HbO için ortalama %63,50 HbR için ortalama %66,50 sınıflandırma doğruluk yüzdesine ulaşmışlardır (Shin et al. 2017).

EEG sinyallerinin oluşturduğu sınırlamalar YKS yardımı ile aşılmaya çalışılmıştır. İlk olarak, BBA komutlarının güvenilir bir şekilde tespit edilmesinin zorluğu, EEG dönem uzunluğu azaldığında artar, bu da yüksek bilgi aktarım hızlarının elde edilmesini zorlaştırır. İkinci olarak, BBA sistemi, özne herhangi bir görevi yerine getirmemesine rağmen EEG sinyallerini genellikle komutlar olarak yanlış sınıflandırır. Bu sınırlamaları aşmak için yapılan çalışmada, SSVEP ile stimülasyon sırasında beyindeki hemodinamik dalgalanmalar, EEG ile eş zamanlı olarak YKS kullanılarak ölçülmüştür. Yapılan çalışmada hata oranlarındaki görece iyileşme %85 ile %53 arasında değişiklik göstermiştir (Tomita et al. 2014).


BBA'lar için derin öğrenme metotlarının da sınıflandırma başarımını arttıracığı yapılan çalışmalarda ortaya çıkmıştır. Cheng ve arkadaşlarının yaptığı çalışmada EEG sinyalleri Çoklu Örnek Öğrenimi (Multiple Instance Learning - MIL) sınıflandırıcıya tabi tutulmuş ve sınıflandırma performansı ölçülmüştür. MIL, her öğrenme örneğinin tek bir özellik vektörü yerine bir örnek çantası içerdiği tümevarımsal makine öğreniminin bir çeşididir. Yapılan çalışmada sunulan model diğer çalışmalar ile kıyaslandığında yüzde 2-8 daha iyi performans sağlamıştır (Cheng et al. 2023).

BBA çalışmaları beynin sınırlarının tamamen çözümlenemediği için hâlâ istenen seviyelere taşınamamıştır. BBA'lar için en önemli sorun sınıflandırıcı performansının artırılmasıdır. Uygun sınıflandırıcı seçimi olmadığı zaman sistem istenen başarıyı gösterememektedir. Ayrıca öznitelik çıkarımı da sınıflandırıcı performansını etkilemektedir.

BBA'lar için önemli bir diğer sorun ise nörolojik aktiviteyi sağlıklı bir şekilde pratik olarak kayıt edebilmektir. Bu sorun için cihaz üreticileri çalışmalarını sürdürmektedirler. EEG tekniği yerine implante edilebilir bir sistem üzerine çalışmalar sürmektedir. Beyin üzerine açılacak milimetrik delikler sayesinde buraya yerleştirilecek araçlar ile nöral aktivite kayıt altına alınmaya başlanacaktır.

3. MATERYAL ve YÖNTEM

Bu bölümde çalışmada kullanılan açık erişimli veri seti tanıtılmış ve sınıflandırma başarımına ait detaylar verilmiştir. Kullanılan yazılımlar ve veri setini elde etmede kullanılan donanımlar hakkında bilgi verilmiştir. Çalışmada takip edilen temel akış diyagramı Şekil 3.1. ile sunulmuştur.




Şekil 3.1. Çalışmamızın akış diyagramı

3.1. Materyal

Kullanılan yöntem Matlab ile implemente edilmiştir. Matlab araçlarından EEGLab ile EEG sinyalleri işlenmiş, BCI (Berlin Brain Computer Interface) aracı ile de açık erişimli veri setinden EEG ve YKS kanalları çıkartılmıştır. Sınıflandırıcı performanslarını ölçmek için WEKA arayüzü kullanılmıştır.

EEG verileri çok kanallı BrainAmp EEG amplifier (Brain Products GmbH, Gilching, Germany) cihazı ile kayıt edilmiştir (Şekil 1.6). Örnekleme oranı 1000 Hz.'dir. Cihazın 30 aktif EEG elektrodu uluslararası 10-5 sistemine göre kumaş başlığa yerleştirilmiştir (Şekil 3.2.).

YKS verileri ise NIRScout (NIRx Medizintechnik GmbH, Berlin, Germany) cihazı ile kayıt altına alınmıştır. Örnekleme oranı 10,4 Hz olmuştur. Cihaz ile 60 kaynak ve 60 dedektör frontal, motor, parietal ve oksipital bölgelere yerleştirilmiştir. 36 kanal yapılandırılmıştır. Kanallar uluslararası 10-5 sistemine göre yerleştirilmiştir.



Şekil 3.2. EEG (Yeşil) ve YKS (Kırmızı) elektrotları konumları (Shin et al. 2018)

3. MATERYAL ve YÖNTEM

Deneyde EEG sinyallerini elde etmek için kullanılan EEG kanallarına ait lokasyonları tablo halinde verilmiştir (Çizelge 3.1).

Çizelge 3.1. EEG lokasyonları


clab	X	Y	Z
Fp1	-0,309	0,9511	0,0001
AFF5h	-0,5417	0,7777	0,3163
AFz	0,0000	0,923	0,3824
F1	-0,2888	0,6979	0,6542
FC5	-0,8709	0,3373	0,3549
FC1	-0,3581	0,377	0,8532
T7	-10,000	0,0000	0,0000
C3	-0,7066	0,0001	0,7066
Cz	0,0000	0,0002	10,000
CP5	-0,8712	-0,3372	0,3552
CP1	-0,358	-0,3767	0,8534
P7	-0,809	-0,5878	-0,0001
P3	-0,5401	-0,6724	0,5045
Pz	0,0000	-0,7063	0,7065
POz	0,0000	-0,923	0,3824
O1	-0,309	-0,9511	0,0000
Fp2	0,3091	0,9511	0,0000
AFF6h	0,5417	0,7777	0,3163
F2	0,2888	0,6979	0,6542
FC2	0,3581	0,377	0,8532
FC6	0,8709	0,3373	0,3549
C4	0,7066	0,0001	0,7066
T8	10,000	0,0000	0,0000
CP2	0,358	-0,3767	0,8534
CP6	0,8712	-0,3372	0,3552
P4	0,5401	-0,6724	0,5045
P8	0,809	-0,5878	-0,0001
O2	0,309	-0,9511	0,0000
TP9	-0,8777	-0,2852	-0,3826
TP10	0,8777	-0,2853	-0,3826

Deneyde NIRS sinyallerini elde etmek için kullanılan NIRS kanallarına ait lokasyonları tablo halinde verilmiştir (Çizelge 3.2).

Bu çalışmada kullanılan veri seti 26 sağ eli ve sağlıklı katılımcıyla oluşturulmuştur. Katılımcıların 9'u erkek 17'si kadınlardan oluşmaktadır. Katılımcıların yaş aralığı 17 ile 33 arasındadır. Katılımcıların hiçbir sonucu etkileyebilecek nörolojik, psikolojik ve beyin ile ilgili diğer hastalığı bulunmamaktadır. Tüm katılımcılara deneysel prosedür hakkında bilgi verilmiş ve yazılı onayları alınmıştır. Bu çalışma Helsinki deklarasyonuna göre yapılmıştır (Shin et al. 2018).

Katılımcılar 24" LCD ekran karşısına oturmuşlardır. Ekran ile katılımcıların gözleri arasındaki mesafe yaklaşık olarak 1,2 m'dir. Gözlerini monitörden ayırmamaları ve mümkün olduğunca hareket etmemeleri için talimat verilmiştir. Deney her biri 3 oturumlu n-back, DSR ve Word Generation (WG) görevinden oluşmaktadır (Shin et al. 2018).

Bu çalışmada kullanılan veri kümesinin her katılımcı için üç oturumu bulunmakta ve her bir oturum her biri on WD denemesi ve Baseline (BL) görevi içerir (Şekil 3.3.). Tek bir deneme 2 s'lik bir talimat, 10 s'lik bir görev süresi ve 13-15 s'lik bir dinlenme periyodundan oluşmaktadır. Görev periyodu kısa bir bip sesi (250 ms) ile başlamakta ve bir kısa bip sesi (250 ms) ve monitörde 1 saniye boyunca görüntülenenen 'DUR' işareti ile sona ermektedir. Toplamda 60 deneme yapılmıştır (Shin et al. 2018).



Şekil 3.3. Deneysel prosedür

Çizelge 3.2. NIRS lokasyonları

clab	X	Y	Z
AF7	-0,5878	0,809	0,0000
AFF5	-0,6149	0,7564	0,2206
AFp7	-0,454	0,891	0,0000
AF5h	-0,4284	0,875	0,2213
AFp3	-0,2508	0,9565	0,1438
AFF3h	-0,352	0,8111	0,4658
AF1	-0,1857	0,915	0,3558
AFFz	0,0000	0,8312	0,5554
AFpz	0,0000	0,9799	0,1949
AF2	0,1857	0,915	0,3558
AFp4	0,2508	0,9565	0,1437
FCC3	-0,6957	0,1838	0,6933
C3h	-0,555	0,0002	0,8306
C5h	-0,8311	0,0001	0,5552
CCP3	-0,6959	-0,1836	0,6936
CPP3	-0,6109	-0,5259	0,5904
P3h	-0,4217	-0,6869	0,5912
P5h	-0,6411	-0,6546	0,3985
PPO3	-0,4537	-0,796	0,3995
AFF4h	0,352	0,8111	0,4658
AF6h	0,4284	0,875	0,2212
AFF6	0,6149	0,7564	0,2206
AFp8	0,454	0,891	0,0000
AF8	0,5878	0,809	0,0000
FCC4	0,6957	0,1838	0,6933
C6h	0,8311	0,0001	0,5552
C4h	0,555	0,0002	0,8306
CCP4	0,6959	-0,1836	0,6936
CPP4	0,6109	-0,5258	0,5904
P6h	0,6411	-0,6546	0,3985
P4h	0,4216	-0,687	0,5912

Çizelge 3.2. (Devam)

PPO4	0,4537	-0,796	0,3995
PPOz	0,0000	-0,8306	0,5551
PO1	-0,1858	-0,9151	0,3559
PO2	0,1859	-0,9151	0,3559
POOz	0,0000	-0,9797	0,1949

3.2. Yöntem

3.2.1. Ön işleme adımları

a. Temel Düzeltme (Baseline Correction)

EEG bir zaman çözümü sinyali olmasıyla beraber deneyle alakası olmayan zamansal kaymalara sahip olabilmektedir. Bu tür zamansal kaymaların neden olduğu olumsuzluklardan kurtulmak için Temel Düzeltme adı verilen işlemi yapmak gelenek halini almıştır. Temel olarak EEG aktivitesinin olay meydana gelmeden önceki süre boyunca, olay meydana geldiği süre müddetince düzeltilmesi işidir. Temel düzeltme için çeşitli uygulama ve yaklaşımlar bulunmaktadır.

Temel düzeltme ön işlemede önemli bir adımdır. Sinyali girişim etkilerinden ve arka plan etkileri ile lekelerden temizlemek için kullanılan önemli bir tekniktir. Temel düzeltme işlemi sinyali istenen seviyeye çekmek için kullanılan bir ön işleme adıımıdır.

b. Filtreleme

Filtreleme işaret ve sinyal işleme alanlarındaki temel işlemlerden biridir. Temel olarak filtreleme bir sinyal elde edilirken istenmeyen sinyallerle parazitlerin ayrıştırılarak sinyalin istenen duruma getirilme adıımıdır. Özellikle istenmeyen gürültüleri temizlemek için frekans seçici filtreler kullanılmaktadır.

Filtre tasarımında 3 tür sınıflandırma yapmak mümkündür:

1. Genlik cevabını temel alan ayırık zamanlı filtreler (Alçak geçiren, yüksek geçiren, bant geçiren, bant durduran filtreler)
2. Impuls cevabının uzunluğunu temel alan ayırık zamanlı filtre tasarımı (Sonsuz uzunluklu impuls cevabına sahip IIR (infinite impulse response) filtre ve sonlu uzunluklu impuls cevabına sahip FIR (finite impulse response) filtreler
3. Faz cevabını temel alan ayırık zamanlı filtre tasarımı (Sıfır faz, Lineer faz, Genelleştirilmiş lineer faz ve Lineer olmayan faz filtreler)

c. Temel Bileşen Analizi (TBA)

Biyomedikal uygulamalarında elde edilen biyomedikal sinyaller önce işlenerek çevresel ve sensör gürültülerinden temizlenmek durumundadır. Eğer gürültülerin frekans bilgileri biliniyor ise burada filtreler kullanılabilir. Ancak gürültüye ilişkin kaynak hakkında bilgi sınırlı veya yoksa bu durumda filtreleme için istatistiksel bir yöntem olan TBA kullanılabilir. TBA kör sinyal ayrımı olarak da adlandırılmaktadır.

TBA doğrusal olarak karıştırılmış bir sinyaldeki birleşenleri bulmak için kullanılabilir. Ayrıca bu bileşenler diğer istenmeyen bileşenlerden filtrelenebilir. TBA için birçok filtre ve tanıma uygulaması mevcuttur. Konuşma tanıma, konuşma filtreleme, sinyal geliştirme ve görüntü gürültü filtreleme bunlardan bazılarıdır.

TBA korelasyona dayalı yöntemlerin aksine, sinyallerin ilişkilerini bozmakla kalmaz, sinyalleri bağımsızlaştırır.

3.2.2. Öznitelik çıkarım yöntemleri

Birçok özellik hastanın HbO ve HbR aktivitesine dayalı olarak tahmin edilebilir. Bu özellikler arasında ortalama, tepe noktası ve eğim en sık kullanılan yöntemler olarak karşımıza çıkmaktadır. Bu özellikleri tahmin edebilmek için önceden belirlenmiş bir Window gereklidir.

a. Ortalama

Sinyal ortalaması aşağıda bulunan formüle göre hesaplanır;

$$\mu_w = \frac{1}{N_w} \sum_{k=k_1}^{k_2} \Delta HbX(k) \quad (3.1)$$

Bu formülde w pencereyi, belirli bir pencere için ortalama değeri, k1 ve k2 başlangıç ve bitiş zamanını, Nw penceredeki gözlem sayısını ve HbX ise HbO veya HbR değerlerini ifade eder.

b. Tepe Değer

Bu özellik belirli bir pencerede sinyalin en yüksek değeridir. Bazı çalışmalarda en yüksek değerlerin en iyi sonuçları verdiği bildirilmiştir.

c. Eğim

Sinyal eğimini hesaplamanın en yaygın yöntemi önceden belirlenmiş bir aralığın başlangıç ve bitiş noktalarındaki değerlerin farkını bularak bunu eğimi hesaplamada kullanmaktır.

d. Minimum

Belirli bir pencerede bulunan değerlerin en küçüğünün alındığı yöntemdir. Pek yaygın kullanılmamaktadır.

e. Çarpıklık ve Basıklık

Çarpıklık (Skewness) aşağıdaki formül yardımı ile hesap edilir;

$$\text{skew}_w = \frac{E_x(\Delta HbX_w - \mu_w)^3}{\sigma^3} \quad (3.2)$$


Burada sigma verilen pencere için HbX standart sapması iken Ex, HbX'in beklentisidir.

Basıklık (Kurtosis) ise aşağıdaki formülle hesap edilir;

$$\text{kurt}_w = \frac{E_x(\Delta HbX_w - \mu_w)^4}{\sigma^4} \quad (3.3)$$

f. Çoklu Örnek Öğrenimi

Çoklu örnek öğrenmede eğitim seti, her biri birçok örnek içeren birçok çantadan oluşur. Bir çanta, en az bir pozitif örnek içeriyorsa pozitif olarak etiketlenir; aksi halde negatif çanta olarak etiketlenir (Şekil 3.4.). Görev, görünmeyen çantaları doğru bir şekilde etiketlemek için eğitim setinden bazı kavramlar öğrenmektir (Zhou 2004). Tüm eğitim örneklerinin bilinen etiketlere sahip olduğu denetimli öğrenmeden farklı olarak, çoklu örnekli öğrenmede eğitim örneklerinin etiketleri bilinmez iken; tüm eğitim örneklerinin bilinen etiketler olmadığı denetimsiz öğrenmeden farklı olarak, çoklu örnek öğrenmede eğitim çantalarının etiketleri bilinmektedir. Eğitim örneklerinin etiketlerinin ertelendiği takviyeli öğrenmeden farklı olarak, çok örnekli öğrenmede herhangi bir gecikme yoktur (Carbonneau et al. 2018).



Şekil 3.4. Multi instance learning

g. HJORTH Parametreleri

HJORTH parametreleri 1970 yılında Bo HJORTH tarafından bulunan zaman domenini sinyal işlemede kullanılan istatistiksel parametrelerdir. Öznitelik çıkarımlar için EEG sinyal analizinde sıklıkla kullanılır. Parametreleri Aktivite, Hareketlilik ve Karmaşıklık. Ayrıca robotik alanda yüzey algılama ve dokunma modalitesi sınıflandırılmasında dokunsal sinyal işlemede kullanılmaktadır.

Aktivite (Activity) zaman fonksiyonunun varyansını veya sinyal gücünü temsil eder. Hareketlilik (Mobility) parametresi ise güç spektrumunun ortalama frekansını veya standart sapma oranını temsil eder. Karmaşıklık (Complexity) ise sinyalin frekansındaki değişikliği temsil eder. Burada sinyalin sinüs dalgası ile benzerliği karşılaştırılır.

3.2.3. Öznitelik füzyonu

Genel olarak birden çok kaynaktan gelen veriler üzerinde tahmin gerektiren tüm görevler data/bilgi birleştirme yöntemlerini kullanabilir. Bilgi birleştirme ve data birleştirme benzer anlamlarda kullanılsa da ham veriler için data birleştirme, işlenmiş verileri tanımlamak için ise bilgi birleştirme terimi kullanılmaktadır.

Data birleştirme işlemi için araştırmacılar, tahminleri belirlemek ve durumları eksiksiz zamanında değerlendirilmesi için bir veya birden fazla kaynaktan gelen verilerin ve bilgilerin ilişkilendirilmesi, korelasyonu ve kombinasyonu ile ilgilenen çok yönlü bir süreçtir tanımında mutabık kalmışlardır.

Veri füzyonunu kısaca gelişmiş bilgiyi elde edebilmek için yapılan birden fazla kaynağın kombinasyon çalışması olarak tanımlanabilir. Bu işlemten sonra bilgi daha ucuz, daha kaliteli ve daha ilgili olmaktadır.

Veri birleştirme teknikleri birden fazla veriyi birleştirmek için çok sensörlü ortamlarda sıklıkla kullanılmaktadır. Çoklu sensör ortamlarında veri birleştirmenin kullanım amacı, kaynaklardan gelen verileri kullanarak daha düşük algılama hatası ve daha yüksek güvenilirliği elde etmektir.


a. Kanonik Korelasyon Analizi

Hotelling tarafından 1936 yılında çok değişkenli regresyon analizinin bir türü olarak geliştirilen kanonik korelasyon analizi, en az iki değişkene sahip veri setleri arasındaki ilişkinin durumunu ve miktarını ölçmek için kullanılan bir yöntemdir. Kanonik korelasyon analizi bir veri setinde bulunan değişkenlerin doğrusal kombinasyonları ve diğer veri setindenki değişkenlerin doğrusal kombinasyonları arasında bulunabilecek korelasyonları belirlemeye çalışır. Amaç, doğrusal kombinasyonların tüm ortogonal çiftleri arasındaki daha büyük korelasyonlara sahip olanlarını belirlemektir. Doğrusal kombinasyon çiftleri kanonik varyeteler olarak adlandırılır ve bunların korelasyonları da kanonik korelasyonlardır. Kanonik korelasyon iki değişken seti arasındaki ilişkinin gücünün ölçüsüdür. Yöntemin esası, iki değişken seti arasındaki yüksek boyutlu ilişkiyi, maksimum korelasyonu yansıtabilecek daha az sayıda kanonik varyete çiftleriyle özetleyebilmek çabasına dayanır (Bilgin ve Esenbuğa 2009).

3.2.4. Sınıflandırma yöntemleri

a. Rastgele Ormanlar

Rastgele Ormanlar (RF), denetimli öğrenme tekniğine ait popüler bir makine öğrenme algoritmasıdır (Şekil 3.5.). Makine öğrenmesinde hem Sınıflandırma hem de Regresyon problemleri için kullanılabilir. Karmaşık bir sorunu çözmek ve modelin performansını iyileştirmek için birden çok sınıflandırıcıyı birleştirme süreci olan topluluk öğrenme kavramına dayanır. Adından da anlaşılacağı gibi, RF belirli bir veri kümesinin çeşitli alt kümelerinde bir dizi karar ağacı içeren ve bu veri kümesinin tahmin doğruluğunu iyileştirmek için ortalamayı alan bir sınıflandırıcıdır. RF, tek bir karar ağacına güvenmek yerine, her ağaçtan tahmin alır ve tahminlerin çoğunluk oylarını temel alır ve nihai çıktıyı tahmin eder.




Şekil 3.5. Random forest

b. Naive Bayes (NB)

Naive Bayes sınıflandırıcısının temeli Bayes teoremine dayanır. Tembel bir öğrenme algoritmasıdır aynı zamanda dengesiz veri kümelerinde de çalışabilir. Algoritmanın çalışma şekli bir eleman için her durumun olasılığını hesaplar ve olasılık değeri en yüksek olana göre sınıflandırır. Az bir eğitim verisiyle çok başarılı işler çıkartabilir. Test kümesindeki bir değer için eğitim kümesinde gözlemlenemeyen bir değer varsa olasılık değeri olarak 0 verir yani tahmin yapamaz. Bu durum genellikle Zero Frequency (Sıfır Frekans) adıyla bilinir. Bu durumu çözmek için düzeltme teknikleri kullanılabilir. En basit düzeltme tekniklerinden biri Laplace tahmini olarak bilinir.

c. K En Yakın Komşu Algoritması (kNN)


kNN algoritmasında bir verinin bir kümeye en yakın olma durumu bulunmaya çalışılır (Şekil 3.6.). Sınıflandırılmış bir veri setine yeni bir veri eklendiğinde bu verinin gruplanmış k tane veriye olan uzaklığı analiz edilmeye çalışılır. K için verilen değer kaç ise komşuluk için o değer dikkate alınır (Naseer et al. 2016).



Şekil 3.6. kNN algoritması

d. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (Support Vector Machine) genellikle sınıflandırma problemlerinde kullanılan gözetimli öğrenme yöntemlerinden biridir (Şekil 3.7.). Bir düzlem üzerine yerleştirilmiş noktaları ayırmak için bir doğru çizildiği ve bu doğrunun, iki sınıfının noktaları için de maksimum uzaklıkta olmasını amaçlandığı bir sınıflandırma algoritmasıdır. Karmaşık ama küçük ve orta ölçekteki veri setleri için uygundur (Papadonikolakis and Bouganis 2010).



Şekil 3.7. SVM temsili gösterimi

e. Doğrusal Ayırtaç Analizi (LDA)

Doğrusal Ayırtaç Analizi veya LDA, bir boyutluluk azaltma tekniğidir. Orjinal teknik, 1936 yılında Ronald A. Fisher tarafından geliştirildi ve Linear Discriminant veya Fisher's Discriminant Analysis olarak adlandırıldı. Orijinal Doğrusal Ayırtaç, iki sınıflı bir teknik olarak tanımlandı. LDA, rekabetçi makine öğrenimi modelleri oluşturmanın bir parçası olarak kabul edilen denetimli bir sınıflandırma tekniğidir. Hem LDA hem de Temel Bileşen Analizi (PCA), boyut indirgeme için yaygın olarak kullanılan lineer dönüştürme teknikleridir. PCA, sınıf etiketlerini "yok saydığından" ve amacı, bir veri kümesindeki varyansı en üst düzeye çıkaran yönleri (temel bileşenler olarak adlandırılan) bulmak olduğundan, "denetimsiz" bir algoritma olarak tanımlanabilir. PCA'nın aksine, LDA "denetlenir" ve çoklu sınıflar arasındaki ayrımı en üst düzeye çıkaran eksenleri temsil edecek yönleri ("doğrusal ayırmacılar") hesaplar.

Çalışmada kullanılan sınıflandırıcılara ait parametreler Çizelge 3.3. ile verilmiştir.

Çizelge 3.3. Kullanılan sınıflandırıcıların parametreleri

SVM			
BatchSize	Cache Size	coef0	cost
100	40	0	1
NB			
BatchSize	Debug	Num Dec Place	Use Kernel Estimator
100	False	2	False
kNN			
BatchSize	k	Cross Validate	Debug
100	1	False	False
LDA			
BatchSize	Debug	Num Dec Place	Ridge
100	False	2	1.0E-6
RF			
BatchSize	Max Depth	Bag Size Percent	Num Dec Place
100	0	100	2

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Zaman etki alanında EEG'den 280, OXY ve DEOXY'den 360 öznitelik çıkarılmıştır. Sınıf etiketleri %50 oranında dengeli bir dağılıma sahiptir. EEG özniteliklerinden 43 bölüm, OXY özniteliklerinden 263 bölüm ve DEOXY özniteliklerinden 167 bölüm elde edilmiştir.

Zaman etki alanında EEG için 280, OXY ve DEOXY için 360'ar öznitelik çıkarıldığı belirtilmiştir. MIL tekniği bu öznitelikleri EEG için 43 bölüme, OXY için 263 bölüme ve DEOXY için 167 bölüme ayırmıştır. Her biri birçok örnek içeren birçok çantadan oluşan bu teknik sınıflandırma başarımlarında etkili olmuştur. Özellikle SVM ile EEG kanalında en yüksek başarımlar elde edilmiştir (Çizelge 4.1).

Çizelge 4.1. Zaman domen sınıflandırıcı performansları

	EEG			OXY			DEOXY		
	Acc*	Pre	F-Mea	Acc	Pre	F-Mea	Acc	Pre	F-Mea
NB	0,716	0,716	0,716	0,663	0,663	0,663	0,621	0,653	0,599
LDA	0,566	0,566	0,467	0,892	0,892	0,891	0,772	0,835	0,761
SVM	0,967	0,967	0,967	0,892	0,892	0,891	0,772	0,835	0,761
KNN	0,697	0,697	0,697	0,893	0,893	0,893	0,716	0,766	0,702
RF	0,824	0,599	0,599	0,892	0,892	0,891	0,772	0,835	0,761
* Weighted Average Accuracy									

Frekans etki alanında ise EEG'den 1142, OXY ve DEOXY'den 1198 öznitelik çıkarıldı. EEG özniteliklerinden 263 bölüm, OXY özniteliklerinden 33 bölüm ve DEOXY özniteliklerinden 25 bölüm elde edilmiştir (Çizelge 4.2.).

EEG kanalının 5 farklı band içermesi ve sinyalin frekans özniteliklerinde etkin bilgi taşıması sınıflandırma başarımlarını olumlu yönde etkilemiştir. Ancak YKS için aynı olumlu artış olmamıştır. Çünkü bu çalışmada kullanılan veri setinin 10 Hz ile örneklenmiş olması ve bu örnekleme frekansı üzerinde bilgi taşınamaması başarımın düşük olmasına neden olmuştur.

Çizelge 4.2. Frekans domeni sınıflandırıcı performansları

	EEG			OXY			DEOXY		
	Acc*	Prec	F-Mea	Acc	Prec	F-Mea	Acc	Prec	F-Mea
NB	0,721	0,722	0,721	0,533	0,598	0,439	0,54	0,628	0,446
LDA	0,976	0,976	0,976	0,562	0,767	0,458	0,561	0,756	0,458
SVM	0,976	0,976	0,976	0,562	0,767	0,458	0,561	0,756	0,458
KNN	0,871	0,871	0,871	0,55	0,688	0,449	0,555	0,718	0,453
RF	0,976	0,976	0,976	0,562	0,767	0,458	0,561	0,756	0,458
* Weighted Average Accuracy									

Precision ve F-Measure değerlerinden TP Rate değerinin her ne kadar %94'ler seviyesinde olsa da ağırlıklı başarımlar %53 seviyelerindedir. Sınıflandırıcı örnekleri belli bir gruba yığılmıştır. Dolayısıyla bu sınıflandırıcılar FP Rate değerini de yüksek bulmuşlardır. MIL yöntemi LDA, SVM ve RF sınıflandırıcılarında yüksek performans göstermiştir.


Öznitelik seviyesinde yapılan birleştirme işleminden elde edilen öznitelik verileri şu şekildedir. Her iki öznitelik birleşimi ile 560 öznitelik elde edilmiştir. EEG-OXY özniteliklerinden 269, EEG-DEOXY özniteliklerinden 263 bölüm elde edilmiştir.

Öznitelik seviyesinde yapılan birleştirme işlemi sınıflandırma başarımları üzerinde pozitif bir etki meydana getirmiştir. Zaten yüksek başarımlar sergileyen EEG kanalına ilaveten YKS kanalından gelen olumlu bir artış hibrit sistemin başarımlarını göstermektedir. Hibrit sistemin sınıflandırma başarımları %98'ler civarında olmuştur. kNN algoritması (k=1) 0.985 (yaklaşık %99) başarımla EEG-DEOXY birleşiminde en yüksek başarımları göstermiştir (Çizelge 4.3.).


Çizelge 4.3. CCA uygulanmış hibrit model sınıflandırıcı performansları

Sınıflandırıcı	EEG-OXY			EEG-DEOXY		
	Acc	Prec	F-Mea	Acc	Prec	F_Mea
NB	0,617	0,703	0,657	0,646	0,74	0,69
LDA	0,982	0,986	0,984	0,981	0,972	0,976
SVM	0,982	0,986	0,984	0,981	0,972	0,976
KNN	0,982	0,986	0,984	0,985	0,972	0,978
RF	0,982	0,986	0,984	0,981	0,973	0,977

Öznitelik seviyesinde yapılan füzyon işleminin sınıflandırma başarımı üzerinde olumlu etkisi olmuştur. Yaklaşık %1 oranında bir iyileşme göstermiştir.



Şekil 4.1. EEG-OXY hibrit karmaşıklık matrisleri




Şekil 4.2 EEG-DEOXY hibrit karmaşıklık matrisleri


5. SONUÇ ve ÖNERİLER

EEG kanalının beş farklı bant içermesi ve sinyalin frekans özniteliklerinde yararlı bilgiler taşıması sınıflandırma performanslarını olumlu yönde etkilemiştir. Ancak aynı olumlu artış YKS için olmamıştır. Çünkü bu çalışmada kullanılan veri seti 10 Hz'de örneklenmiştir. Dolayısıyla EEG gibi 10 Hz üzeri frekanslarda öznitelik çıkarımı içermediğinden düşük performansa yol açmaktadır.

EEG kanalının frekans alanında en iyi performansı ve YKS kanallarında düşük sınıflandırma oranları gösterilmiştir.




Şekil 5.1. Zaman etki alanında sınıflayıcı performansları



Şekil 5.2 Frekans etki alanında sınıflandırıcı performansları

Öznitelik düzeyindeki füzyon işlemi, sınıflandırma performansını olumlu yönde etkilemiştir. Halihazırda yüksek performanslı EEG kanalına ek olarak, YKS kanalından pozitif bir artış, hibrit sistemin başarısını gösterir. Hibrit sistemin sınıflandırma performansı %98 civarındaydı. kNN algoritması ($k=1$) 0,985 (yaklaşık %99) performans ile EEG-DEOXY füzyonunda en yüksek performansı göstermiştir.



Şekil 5.3. Öznitelik düzeyinde füzüyon işlemi sınıflandırıcı performansları
a) EEG-OXY b) EEG-DEOXY.

Hibrit sistemde genel olarak sınıflandırma performansları yüksek olmasına rağmen Naive Bayes sınıflandırıcıda başarımlar düşük olmuştur. Bu durum Naive Bayes sınıflandırıcının olasılıksal diğer sınıflandırıcı türlerinin ise karar ağacı temelli olmasıyla açıklanabilir. Ayrıca Naive Bayes sınıflandırıcısı tembel bir algoritmaya sahiptir.

İlgili çalışmalar incelendiğinde (Çizelge 5.1.) önerilen yöntemin ikili sınıflandırmada başarılı bir sonuç sergilendiği görülmektedir (Çizelge 5.2.).

Çizelge 5.1. Yapılan çalışmamız ile literatürde yapılan diğer çalışmalar

Study	Database	Modal	Features
(Dai et al. 2019)	BCI Competition IV dataset 2b	EEG	STFT
(Zheng et al. 2014)	3 male & 3 female	EEG	Differential entropy
(Naseer et al. 2016)	7 healthy participants	YKS	Mean, Peak, Slope, Variance, Kurtosis, Skewness
(Kabir et al. 2018)	University of Canberra	YKS	PCA, NLPCA, ICA
(Sitaram et al. 2007)	5 healthy participants	YKS	PCA
(Yavuz ve Aydemir 2020)	Open Access Dataset	EEG, YKS	Higuchi fractal dimension, autoregressive
(Shin et al. 2017)	Open Access Dataset	EEG, YKS	ICA, SLOPE, CSP
(Petrantonakis and Kompatsiaris 2018)	8 healthy participants	YKS	Slope, CC, GNIRS
(Yizhen Wen et al. 2019)	24-year-old healthy man	YKS	Multi-grained scanning
(Kevric and Subasi 2017)	BCI Competition IVa	EEG	EMD, DWT, WPD
(Petrantonakis and Kompatsiaris 2018).	8 healthy participants	YKS	Slope, GNIRS
Çalışmamız	Open Access Dataset	EEG, YKS	ICA, CSP, MIL

Çizelge 5.2. Yapılan çalışmamız ile literatürde yapılan diğer çalışmalar

Study	Classifier	Label	CV	Accuracy
(Dai et al. 2019)	CNN, VAE	Right hand, left hand	10 Fold	56.80% (CNN). 60.30% (VAE)
(Zheng et al. 2014)	KNN, SVM, GELM, DBN, DBN-HMM	Emotions	-	86,62%
(Naseer et al. 2016)	LDA, QDA, KNN, SVM, ANN, NAIVE BAYES	Mental Arithmetic, Rest	10 Fold	91.40%. 96.30% (ANN)
(Kabir et al. 2018)	ANN, KNN, SVM	Right Hand Left Hand Gesture	-	100%
(Sitaram et al. 2007)	SVM, HMM	Left Hand Imagery, Right Hand Imagery	5 Fold	93,40%
(Yavuz ve Aydemir, 2020)	KNN,SVM, NAIVE BAYES, RANDOM FOREST, LDA	Mental Arithmetic, Rest	10 Fold	94,08%
(Shin et al. 2017)	LDA	Word Generation, Baseline	10x5 Fold	83,60%
(Petrantonakis and Kompatsiaris 2018)	LDA, SVM	Mental Arithmetic, Rest	10 Fold	92,52%
(Yizhen Wen et al. 2019)	DF	Mental Arithmetic, Digit Sequence, Semantic, Rest	4 Fold	85,70%

Çizelge 5.2. (Devam)

(Kevric and Subasi 2017)	KNN	Right Hand, Foot	10 Fold	94,50%
(Petrantonakis and Kompatsiaris 2018).	LDA, SVM	Mental Arithmetic	-	92,52%
Çalışmamız	NB, SVM, RF, KNN, LDA	Word Generation, Baseline	10 Fold	98,50%

BBA ortaya çıktığı 1970’lerden itibaren gelişmeye devam etmekte. İlk olarak dezavantajlı bireyler için düşünülen sistem daha sonra farklı işlevlere sahip cihaz geliştirmeye kadar evrildi. Beynin ve sinir sisteminin görüntülenmesinde dolaylı veya doğrudan yöntemlerin kullanıldığı beyin bilgisayar arayüzleri, hastalıkların tespiti konusunda tıp adamlarına da büyük yardımları dokunmaktadır.

YKS, nörobilim içinde önemli ve hızla genişleyen bir alanı kaplar ve katılımcıların davranışları üzerinde daha az kısıtlama ile büyük beyin görüntüleme kapasitesi sağlar. Daha da ilginç, bu artık donanım geliştirmedeki ilerlemeler sayesinde daha gerçekçi ortamlarda ve günlük yaşamda gerçekleştirilebiliyor. Örneğin, giyilebilir YKS ve EEG cihazlarının mevcudiyeti, nöro gelişimde yeni ve potansiyel olarak devrim niteliğinde nörogörüntüleme araştırmalarının yolunu açıyor.

Bununla birlikte, bilişsel sinirbilimde YKS için henüz çok erken. Örneğin, oksihemoglobin ve deoksihemoglobin sinyallerinin farklı beyin bölgelerinde ve diğer görev ve koşullarda sınıflandırma performanslarına katkısı araştırılmaya devam etmektedir. Bu tür araştırmalarda temel keşifler olabilir. Ancak çok kanallı (EEG+YKS) çalışmaların sınıflandırma performanslarına her zaman olumlu katkı sağladığı her zaman gösterilmiştir.

Sonuç olarak BBA teknolojisi gelişmekte ve bu gelişmelerde hibrit çalışmalar önemli bir yer tutmaktadır. Sistemin başarımı sınıflandırıcı başarımı ile doğru orantılı

olduğu için Çoklu Örnek Öğrenimi gibi sınıflandırma performansını arttırıcı etkiye sahip algoritmaların kullanımı önemini göstermiştir. Çoklu Örnek Öğrenimi sınıflandırıcı performanslarını olumlu yönde etkilemiştir.

Bu çalışmada farklı yapılarıdaki NB, RF, SVM, LDA ve kNN sınıflandırıcıları seçilmiştir. Sistem performansının arttırılması için başka sınıflandırıcılar seçilebilir. Ayrıca öznitelik çıkarımı için zaman frekans etki alanından öznitelik çıkarımı yapılabilir.



KAYNAKLAR

- Aydemir, Ö. 2022. Beyin bilgisayar arayüzü ve geleceği. *Journal of Investigations on Engineering and Technology*, 5(2), 135-141
- Bansal, D., and Mahajan, R. 2019. EEG-based brain-computer interfacing (BCI). *EEG-based brain-computer interfaces*. Elsevier, Amsterdam, 21-71.
- Bilgin, Ö. C., Esenbuğa, N. 2009. Morkaraman kuzularının vücut ölçüleri ve karkas parça ağırlıkları arasındaki ilişkinin değerlendirilmesinde kanonik korelasyon analizinin kullanılması. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 40(2), 1-10.
- Carbonneau, M. A., Cheplygina, V., Granger, E., Gagnon, G. 2018. Multiple instance learning: A survey of problem characteristics and applications. *Pattern Recognition*, 77, 329-353.
- Cheng, L., Luo, S., Li, B., Liu, R., Zhang, Y., Zhang, H. 2023. Multiple-instance learning for EEG based OSA event detection. *Biomedical Signal Processing and Control*, 80, 104358.
- Dai, M., Zheng, D., Na, R., Wang, S., Zhang, S. 2019. EEG classification of motor imagery using a novel deep learning framework. *Sensors*, 19(3), 551.
- Haihong, Z., Cuntai, G. 2006. A kernel-based signal localization method for nirs brain-computer interfaces. In *18th International Conference on Pattern Recognition*, 1158-1161.
- Kabir, M. F., Islam, S. M. R., Huang, X. 2018. Towards the Appropriate Feature Extraction and Event Classification Methods for NIRS Data. In *2018 International Conference on Computer, Communication, Chemical, Material and Electronic Engineering*, 1-4.
- Lee, B. H., Cho, J. H., Kwon, B. H. 2023. Hybrid Paradigm-based Brain-Computer Interface for Robotic Arm Control. In *2023 11th International Winter Conference on Brain-Computer Interface*, 1-4.
- Naseer, N., Qureshi, N. K., Noori, F. M., Hong, K. S. 2016. Analysis of different classification techniques for two-class functional near-infrared spectroscopy-based brain-computer interface. *Computational Intelligence and Neuroscience*, 1-16.
- Papadonikolakis, M., Bouganis, C. S. 2010. A novel FPGA-based SVM classifier. In *2010 International Conference on Field-Programmable Technology* 283-286.
- Petrantonakis, P. C., Kompatsiaris, I. 2018. Single-trial NIRS data classification for brain-computer interfaces using graph signal processing. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(9), 1700-1709.

- Shin, J., von Lühmann, A., Blankertz, B., Kim, D. W., Jeong, J., Hwang, H. J., Müller, K. R. 2016. Open access dataset for EEG+ NIRS single-trial classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(10), 1735-1745.
- Shin, J., Von Lühmann, A., Kim, D. W., Mehnert, J., Hwang, H. J., Müller, K. R. 2018. Simultaneous acquisition of EEG and NIRS during cognitive tasks for an open access dataset. *Scientific Data*, 5(1), 1-16.
- Sitaram, R., Zhang, H., Guan, C., Thulasidas, M., Hoshi, Y., Ishikawa, A., Birbaumer, N. 2007. Temporal classification of multichannel near-infrared spectroscopy signals of motor imagery for developing a brain-computer interface. *NeuroImage*, 34(4), 1416-1427.
- Tomita, Y., Vialatte, F. B., Dreyfus, G., Mitsukura, Y., Bakardjian, H., Cichocki, A. 2014. Bimodal BCI using simultaneously NIRS and EEG. *IEEE Transactions on Biomedical Engineering*, 61(4), 1274-1284.
- Xiao, X., Xu, M., Wang, Y., Jung, T. P., Ming, D. 2019. A comparison of classification methods for recognizing single-trial P300 in brain-computer interfaces. In 2019 41st Annual International Conference of The IEEE Engineering in Medicine and Biology Society, 3032-3035.
- Yavuz, E., Aydemir, Ö. 2020. Classification of mental arithmetic based hybrid EEG+ NIRS signals. In 2020 28th Signal Processing and Communications Applications Conference, 1-4.
- Yin, X., Xu, B., Jiang, C., Fu, Y., Wang, Z., Li, H., Shi, G. 2015. NIRS-based classification of clench force and speed motor imagery with the use of empirical mode decomposition for BCI. *Medical Engineering and Physics*, 37(3), 280-286.
- Zheng, W. L., Zhu, J. Y., Peng, Y., Lu, B. L. 2014. EEG-based emotion classification using deep belief networks. In 2014 IEEE International Conference on Multimedia and Expo, 1-6.
- Zhou, Z. H. 2004. Multi-instance learning: A survey. Department of Computer Science and Technology, Nanjing University, Technical Representative, 1.