



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**COVID-19’LU ORTAMLARIN DEZENFEKSİYONU İÇİN KULLANILAN
İNSANSIZ BİR KARA ARACININ (İKA) OTOMATİK KONTROLÜ**

YÜKSEK LİSANS TEZİ

Kübra İZCİ

Akıllı Sistemler Mühendisliği Anabilim Dalı

TEMMUZ 2022

BURSA TEKNİK ÜNİVERSİTESİ ❖ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**COVID-19’LU ORTAMLARIN DEZENFEKSİYONU İÇİN KULLANILAN
İNSANSIZ BİR KARA ARACININ (İKA) OTOMATİK KONTROLÜ**

YÜKSEK LİSANS TEZİ

**Kübra İZCİ
(19324814013)**

Akıllı Sistemler Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Gökay BAYRAK

TEMMUZ 2022

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 19324814013 numaralı Yüksek Lisans Öğrencisi Kübra İZCİ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “COVID-19’LU ORTAMLARIN DEZENFEKSİYONU İÇİN KULLANILAN İNSANSIZ BİR KARA ARACININ (İKA) OTOMATİK KONTROLÜ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Gökay BAYRAK**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Serkan ALTUNTAŞ**
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Koray ALTUN
Bursa Teknik Üniversitesi

Teslim Tarihi : 26.07.2022
Savunma Tarihi : 04.07.2022



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.


İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Kübra İZCİ

İmzası:

XXXXXX



Aileme, eřim ve ocuęuma,

ÖNSÖZ

Yüksek lisans tez çalışmam süresince ilgi ve yardımlarını esirgemeyen, bilgi ve tecrübelerini paylaşan ve fikir alışverişinde bulunduğum değerli danışmanım Doç. Dr. Gökay BAYRAK’a teşekkürlerimi sunarım.

Tez çalışmamda başta Ottonom Mühendislik A.Ş. Genel Müdürü Sn. İsmail ÖZCAN olmak üzere, verilerin elde edilmesinde katkısı olan firma personellerine teşekkür ederiz.

Öğrenim hayatım boyunca benden hiçbir zaman desteğini esirgemeyen anneme, babama, eşime ve oğluma sonsuz teşekkürlerimi sunar, kendilerine hayırlı ömürler dilerim.

Haziran 2022

Kübra İZCİ

İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	viii
KISALTMALAR	ix
SEMBOLLER	x
ÇİZELGE LİSTESİ	xi
ŞEKİL LİSTESİ	xii
ÖZET	xiii
SUMMARY	xiv
1. GİRİŞ	15
1.1 Literatür Özeti	16
1.1.1 Bulanık mantık temelli çalışmalar	16
1.1.2 Makine öğrenmesine yönelik çalışmalar	17
2. BEYİN DALGASI SİNYALLERİNİN ELDE EDİLMESİ	21
2.1 Beyin Dalgaları/ Elektroensefalografi (EEG)	22
3. İNCELENEN DALGACIK DÖNÜŞÜMÜ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ	26
3.1 Dalgacık Dönüşümü	26
3.1.1 Sürekli Dalgacık Dönüşümü (SDD)	27
3.1.2 Ayrık Dalgacık Dönüşümü (ADD)	27
3.2 Destek Vektör Makineleri (DVM)	28
3.3 En Yakın k Komşuluğu Algoritması (k-NN)	30
3.4 Karar Ağacı Algoritması (KA)	31
3.5 Topluluk/Kolektif Öğrenme (TÖ)	31
3.6 k-Katlı Çapraz Doğrulama (k-Fold Cross Validation)	32
4. ÖNERİLEN YÖNTEMLER	34
4.1 EEG sinyallerin Alınması & Veri Setinin Oluşturulması	35
4.2 Öznitelik Çıkarımı	38
4.2.1 Sürekli dalgacık dönüşümü ile öznitelik çıkarımı	39
4.2.2 Ayrık dalgacık dönüşümü ile öznitelik çıkarımı	40
4.3 Eğitim Verileri için Model geliştirme	41
4.4 Sınıflandırma	42
4.4.1 k-katlı çapraz doğrulama	42
5. SONUÇLAR	43
5.1 Sürekli Dalgacık Dönüşümü (SDD) ve Topluluk Öğrenmesi (TÖ) Hibrit Makine Öğrenmesi Yöntemi	43
5.2 Ayrık Dalgacık Dönüşümü (ADD) ve Karar Ağacı (KA) Hibrit Makine Öğrenmesi Yöntemi	45
5.3 Sinyal Sınıflandırma Arayüzü	46
6. TARTIŞMA	48
KAYNAKLAR	49
ÖZGEÇMİŞ	51

KISALTMALAR

ADD	: Ayrık Dalgacık Dönüşümü
BBA	: Beyin Bilgisayar Arayüzü
COVID-19	: Korona Virüs 2019
CPU	: Central Processing Unit
ÇÇA	: Çoklu Çözünürlüklü Analiz
DB2	: Daubechies 2
DB4	: Daubechies 4
DDP	: Dalgacık Dönüşüm Paketi
DVM	: Destek Vektör Makineleri
EEG	: Elektroensefalografi
EKG	: Elektrokardiyografi
FCF	: Frekans Cevap Fonksiyonu
GUI	: Graphical User Interfaces
KA	: Karar Ağacı
k-NN	: k-En Yakın Komşu
LabVIEW	: Laboratory Virtual Instrument Engineering Workbench
LDA	: Lineer Diskriminant Analiz
MATLAB	: Matrix Laboratory
OİP	: Olay İlişkili Potansiyel
ROA	: Rasgele Orman Ağacı
SDD	: Sürekli Dalgacık Dönüşümü
SDGUP	: Sabit Durum Görsel Uyaran Potansiyel
TBA	: Temel Bileşenler Analizi
TÖ	: Topluluk Öğrenmesi
UGV	: Unmanned Ground Vehicle
USBÇS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
YSA	: Yapay Sinir Ağları

SEMBOLLER

b	: Ayırtaç-karar değeri
f(t)	: Sinyal
Hz	: Hertz
L² (R)	: Kare-integre edilebilir fonksiyonların uzayı
N	: Veri kümesindeki örnek sayısı
t	: Zaman
w	: Ağırlık vektörü
ψ(t)	: Ana fonksiyon dalgacı

ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1: Ham EEG sinyal verilerinin ilk on satırı.....	36
Çizelge 4.2: Düzenlenmiş EEG sinyal verilerinin ilk on satırı.....	37
Çizelge 5.1: Tez kapsamında denenen yöntemler ve sonuçları	42
Çizelge 5.2: TÖ ile sınıflandırmadaki hata matris sonuçları.....	44



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Beyin lobları	22
Şekil 2.2: Delta dalgaları	23
Şekil 2.3: Teta dalgaları	24
Şekil 2.4: Alfa dalgaları	24
Şekil 2.5: Beta dalgaları	24
Şekil 2.6: Gama dalgaları	25
Şekil 3.1: İki boyutlu örnek uzaylı geniş marjlı hiper düzlemi	29
Şekil 3.2: Topluluk öğrenme metodu kullanarak çeşitlilik azaltımı	32
Şekil 3.3: k-Katlı çapraz doğrulama	33
Şekil 4.1: Çalışmanın ana akış şeması	34
Şekil 4.2: Çalışmanın detaylı akış şeması	35
Şekil 4.3: EEG sinyallerden Neurosky cihazı ile veri alınımı	36
Şekil 4.4: Neurosky cihazı	36
Şekil 4.5: LabVIEW-Neurosky arayüzü	37
Şekil 4.6: Hata tespit, öznitelik ve sınıflandırma algoritması blok diyagramı	39
Şekil 4.7: Ayrık dalgacık dönüştürücü EEG sol sinyal verileri	41
Şekil 4.8: SDD-ADD modelinin eğitim veri modeli süreç diyagramı	41
Şekil 4.9: Sınıflandırma modelinin rapor süreç diyagramı	42
Şekil 5.1: SDD ve TÖ kullanılarak geliştirilen hibrit makine öğrenmesi yöntemi ..	44
Şekil 5.2: SDD ve TÖ hibrit makine öğrenmesi yönteminin doğruluk, özgüllük ve duyarlılık grafiği	44
Şekil 5.3: ADD ve KA kullanılarak geliştirilen hibrit makine öğrenmesi yöntemi ..	45
Şekil 5.4: ADD ve KA kullanılarak geliştirilen yöntemin doğruluk, özgüllük ve duyarlılık grafiği	46
Şekil 5.5: Geliştirilen MATLAB GUI arayüzü	46
Şekil 5.6: Sınıflandırılan MATLAB GUI Örneği	47

COVID-19’LU ORTAMLARIN DEZENFEKSİYONU İÇİN KULLANILAN İNSANSIZ BİR KARA ARACININ (İKA) OTOMATİK KONTROLÜ

ÖZET

Bu çalışmada, insansız bir kara aracının (İKA) beyin (EEG) sinyalleriyle kontrol edilebilmesi için makine öğrenmesi tabanlı hibrit bir yöntem önerilmiştir. Önerilen hibrit yöntemde, dalgacık dönüşümü ile EEG sinyallerinden gerekli öznelik vektörleri elde edilmiş ve karar ağacı modeli kullanılarak bu öznelik sinyalleri sınıflandırılmıştır. Sınıflandırıcı çıkışındaki sinyaller, İKA’nın uygun yönde hareket ettirilebilmesi amacı ile kullanılmıştır. Sistemin eğitimi için 41 kişiden EEG sinyal verileri alınmıştır. Veriler band geçirgen filtreler ile gürültüden arındırılmıştır. EEG sinyallerinden en iyi öz nitelik çıkarımının sağlanabilmesi için sürekli ve ayrık dalgacık dönüşümü yöntemlerinin performansı araştırılmıştır. Baskın özelliklerin yer aldığı bandların eğitim dosyası oluşturulmuştur. Eğitim dosyası k-Katlı Çapraz Doğrulama yöntemi (k-Fold Cross Validation) ile eğitilmiştir. Eğitilen modeller aynı test kümesi üzerinde denenmiş, EEG sinyallerinden elde edilen verilerle, İKA’nın sağ ve sol doğrultuda yönlendirilmesi tahmin edilmeye çalışılmıştır. Sağ ve sol yön tahmini sınıflandırması için bilinen makine öğrenmesi yöntemlerinden performansı en iyi olanın bulunması amaçlanmıştır. Modellerden elde edilen verilerin karşılaştırması sonucunda, ayrık dalgacık dönüşümü ile kullanılan karar ağacı modelinin, diğer modellere göre test verileri üzerinde en fazla doğruluk oranı % 83 ayrıca sürekli dalgacık dönüşümü ve topluluk öğrenmesi ile en fazla doğruluk oranı %95 verdiği sonucuna ulaşılmıştır.

Anahtar kelimeler: Otomatik Sistem, Makine Öğrenmesi, Elektroensefalogram (EEG), Dalgacık Dönüşümü, Karar Ağacı, Topluluk Öğrenmesi

AUTOMATIC CONTROL OF AN UNMANNED LAND VEHICLE USED FOR DISINFENCTION OF ENVIRONMENTS WITH COVID-19

SUMMARY

In this study, a machine learning-based hybrid method is proposed to control an unmanned ground vehicle (UGV) with brain (EEG) signals. In the proposed hybrid method, necessary feature vectors were obtained from EEG signals with wavelet transform and these feature signals were classified using decision tree model. The signals at the output of the classifier are used to move the UGV in the appropriate direction. EEG signal data were taken from 41 people for the training of the system. The data are noise-free with bandpass filters. The performance of continuous and discrete wavelet transform methods has been investigated to obtain the best feature extraction from EEG signals. The training file of the bands with dominant features was created. The training file was trained with the k-Fold Cross Validation method. The trained models were tested on the same test set, and it was tried to predict the right and left direction of the UGV with the data obtained from the EEG signals. It is aimed to find the best performance among the known machine learning methods for right and left direction prediction classification. As a result of the comparison of the data obtained from the models, it was concluded that the decision tree model used with the discrete wavelet transform gave the highest accuracy rate of 83% on the test data compared to other models. In addition, it was concluded that the continuous wavelet transform with ensemble learning gives the highest accuracy rate of 95%.

Keywords: Automatics System, Machine Learning, Electroencephalogram (EEG), Wavelet Transform, Decision Tree, Ensemble Learning

1. GİRİŞ

Yaşamın daha etkin ve pratik ilerlemesi nedeniyle, hızlı bilimsel gelişmelerin paralelinde akıllı teknolojiler de öne çıkmaya başlamıştır. Akıllı sistemler, akıllı endüstriler veya akıllı cihazlar günlük hayatımızda yerini almaya başlamıştır. Akıllı sistemler; önceden edinilmiş verilerin, cihazlarla belirli protokoller sayesinde haberleşmesini sağlayarak, teknolojik işlemlerde insan etkisini en aza indirmeyi hedefleyen sistemlerdir. Akıllı sistemlerin incelediği alt teknolojilerden biri de insansız kara araçları teknolojisidir. İnsansız Kara Aracı (İKA), karada hareket eden ve üzerinde insan varlığı olmayan araçların genel terimidir.

2019 yılının son ayında ortaya çıkan COVID-19 virüs salgını, sağlık, ekonomi ve sosyo kültürel alanlarında küresel bir etki yaratmıştır. Virüs salgınının etkin şekilde yok edilmesi için dezenfeksiyon cihazları önemli rol oynamıştır. Salgının yarattığı birçok olumsuz etki nedeniyle yaşam alanlarının dezenfekte edilmesinin sadece pandemi sürecinde değil, her zaman insan sağlığı açısından öneminin büyük olduğu anlaşılmıştır. Ancak geleneksel yöntemlerle yaşam alanlarının etkili bir şekilde dezenfekte edilemediği görülmüştür. Bu alandaki çalışmalar, özellikle yurt içinde teknolojik olarak henüz istenilen seviyeye ulaşmamıştır. COVID-19 hastalığının hava yoluyla bulaşması, dezenfektan araçlarının yaymış olduğu ışınlar vb. gibi etmenler insan sağlığını tehlikeye atmaktadır.

İKA'ların beyin sinyalleri (EEG) ile hareket ettirilmesi konusu, özellikle pandemi sebebiyle günümüzde önemli araştırma konularından biri olmuştur. Salgın döneminde hasta kişilere yaklaşılmaması ve sağlıklı bireylerin bile birbirleriyle arasındaki mesafe sağlık örgütünün belirlediği şekilde olması gerekmektedir. Özellikle COVID-19 hastası olan bireylere ilaçlarının verilmesi, ateş ölçümü ve hastalık seyrinin düzenli takibi gibi konularda İKA'ların devreye girmesi amaçlanmıştır. İKA'ların yön tayini için giyilebilir cihazların kullanılması da tezde hedeflenilmiştir. Cihazların otomatik hareketi için beyin bilgisayar arayüzlerinden (BBA) yararlanılır. BBA, zihinsel süreçlerimizdeki nöral aktiviteyi doğrudan bilgisayar ekranına aktarımındaki arayüzleri geliştiren bir araştırma alanıdır [1]. Geçmiş zamanlarda maliyetli ve bir o

kadar zaman alıcı olan EEG sinyallerinden veri toplama işlemi, artık giyilebilir ve taşınabilir teknoloji gelişimi sayesinde herhangi bir yerde kolayca toplanabilecek seviyeye gelmiştir. Bu bağlamda dezenfaktan cihazların giyilebilir cihazlar sayesinde yön bulma tahminlemesi insan konforunu artıran, insan sağlığını koruyan, aynı anda zaman ve enerji tasarrufu sağlayan bir yaklaşımdır. EEG sinyallerinin toplanması ve makine öğrenmesi temelli hibrit bir yönlendirme sistemi tasarımı bu tez çalışmasının temelini oluşturmaktadır.

1.1 Literatür Özeti

Literatür incelendiğinde, EEG sinyalleri ile ilgili birçok çalışma yapıldığı ve BBA açısından da iki tipe ayrıldığı gözükmemektedir. Birinci tip: sinyal ve kursör hareketine ilişkilendirilmiş regresyon modeli olarak tanımlanırken, ikinci tip ise sınıflandırma modeli olarak belirtilmektedir. Özellikle son yirmi yılda araştırmacıların sınıflandırma modeline yoğunlaştığı görüldüğü için de birçok çalışma yapılmıştır. Bu çalışmalarda en çok kullanılan yöntemler, bulanık mantık ve makine öğrenmesi temelli yöntemlerdir.

1.1.1 Bulanık mantık temelli çalışmalar

Toprak ve ark. yaptıkları çalışmada [2], epilepsi hastalığının tespiti için EEG sinyallerini kullanmışlardır. Kullandıkları veri seti Bonn Üniversitesi'ndeki Epitoleji veri tabanından alınmış ve EEG sinyallerinden iki küme seçilmiştir. Bu iki kümeden biri gözleri açık sağlıklı insanlarken, diğer küme ise epilepsi hastası olan insanlar olarak belirlenmiştir. Bu sinyallere ayrık dalgacık dönüşümü uygulanıp, Daubechies 2 ve Daubechies 4 dalgacıkları seçilmiştir. Seçilen dalgacıkların öznitelik vektörleri çıkartılmıştır. Çıkartılan öznitelik vektörlerindeki veriler test ve eğitim setine ayrılarak bulanık mantık sistemine dayalı uyarlanır bir ağ ile eğitilip, test edilmiştir. Veriler %99,44 doğruluk oranı ile sınıflandırılmıştır.

Diğer bir çalışmada [3], EEG sinyallerinden epilepsi hastalığının sınıflandırılması için yeni bir yöntem denenerek %99,48 gibi yüksek bir doğruluk oranı elde edilmiştir. Çalışmada ilk adım veri ön işleme; ikinci adım Welch yöntemiyle özellik çıkarımı ve son adım temel bileşen analizi ile boyutsal indirgemedir. Bu işlemlerden sonra, bulanıklaştırma metodunun frekans cevap fonksiyonu (FCF) seçilerek sınıflandırma yapılmış ve en yüksek sonuç elde edilmiştir.

Epilepsi hastalarından alınan EEG sinyallerine ayırık dalgacık dönüşümü uygulanarak özniteliklerin çıkartıldığı başka bir çalışmada [4], uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS) ile sınıflandırma yapılmıştır. USBÇS modelinin toplam sınıflandırma doğruluğu %98,68 bulunmuştur.

1.1.2 Makine öğrenmesine yönelik çalışmalar

Sabit Durum Görsel Uyarın Potansiyel (SDGUP) tabanlı veri analizinin gerçekleştirildiği bir çalışmada [5], bireylerden sağa, sola ve yukarıya bakması istenilerek EEG sinyalleri alınmıştır. Alınan sinyaller band geçiren filtreden elimine edilerek, Hilbert ve kısa zamanlı Fourier dönüşüm işlemleri yapılmıştır. Burada SDGUP'un beyin oksipital bölgesinde nasıl cevap verdiğine bakılmıştır. Sistemin eğitimi, yapay sinir ağları (YSA) ve destek vektör makineleri (DVM) ile yapılmıştır. Eğitilmiş sistemin testi için bireylerden alınan veriler kullanılmış, bireylerin hangi yöne baktığı bulunarak Lego Mindstorm EV3 robotun bu yönlere göre hareket edip etmediği kontrol edilmiştir. Beyin bilgisayar arayüz (BBA) sisteminde, SDGUP cevabına göre ortalama %89 doğruluk başarı oranı elde edilmiştir.

Başka bir çalışmada [6], yukarı ve aşağı imleç hareketinin tahmini yapılmıştır. 2003 yılındaki BCI Competition II yarışmasında sunulan veri setinin ilk adımında en etkin kanal bulunmakta, ikinci adımda ise öznitelik çıkarımı ve sınıflandırma yapılmaktadır. İlk adımda ayırık dalgacık dönüşümü (ADD) kullanılmakta, ardından istatistiksel parametreleri hesaplanıp k-en yakın komşu (k-NN) ile sınıflandırma yapılmaktadır. En etkin kanalın A1 olduğu bulunmuştur. En etkin kanal üzerinde yukarı ve aşağı imleç hareketinin öznitelik ve sınıflandırma için üç farklı yaklaşımı incelenmiştir. En yüksek doğruluk sonucunun %94,88 ile hibrit yaklaşım ve destek vektör makineleri (DVM) sınıflandırması ile olduğu bulunmuştur.

Diğer bir çalışmada [7] ise konuşma rahatsızlığı olan bireylerin evde bakım sırasında açlık ve tokluk durumlarını izlenebilecek beyin bilgisayar arayüzü (BBA) tasarımına odaklanılmıştır. 20 sağlıklı bireyden gözler açık, kapalı ve olay ilişkili potansiyel (OİP) verileri toplanılmıştır. Sinyaller filtreleme işleminden geçirilerek OİP'li veriler istatistiksel performans özellikleri çıkartılmıştır. Gözler açık ve kapalı sinyallerden ise dalgacık dönüşüm paketi (DDP) yöntemi kullanılıp, özellik seçiminde Lineer Diskriminant Analiz (LDA) en başarılı doğruluk oranına sahip özelliklerin sınıflandırılması yapılmıştır. Daubechies 4 dalgacığı, gözler açık EEG ölçümlerinde karar ağacı (KA) sınıflandırıcısı kullanılarak en fazla %85 başarı sağlanmıştır. Gözler

kapalı EEG ölçümlerinde ise test doğruluk oranında %95 başarı oranı ile DVM sınıflandırıcısı daha başarılı olmuştur. OİP ölçümlerinde basıklık-çarpıklık istatistiksel analiz yöntemleri 3 katlı çapraz doğrulama yapılarak doğruluk daha da geliştirilmiş ve %97,62 sonucuna ulaşılmıştır.

Epilepsi krizinin tahmini üzerine yapılan bir çalışmada [8], Bonn Üniveritesi Epitoloji Bölümü epilepsi hasta EEG veri seti kullanılarak %99,78 doğruluk oranı ile farklı bir yaklaşım sunmuştur. Sinyaller üzerinde hiper parametre optimizasyonu yapıp, Rassal Orman kullanılarak sınıflandırma modeli yapılmıştır. Sınıflandırma sonucunda, özgülük ve hassasiyet değerleri sırasıyla %99,95 ve %99,61 olarak elde edilmiştir.

İbrahim ve ark. [9] ise yaptıkları çalışmada sürücü yorgunluğunu tespit uygulamaları için, EEG sinyallerinden yararlanarak yorulma izleme ve algılama tahmini yapmışlardır. Sinyallerin öznitelik (birleşik entropi) çıkarımı ile destek vektör makineleri (DVM) ve rastgele orman ağacı (ROA) sınıflandırılmasıyla, sırasıyla %98,7 ve %97,5'lik en iyi yorgunluk algılama sonuçlarına ulaşılmıştır.

Demir yaptığı çalışmada [10], kafa travması geçirmiş 10 hastadan elde edilen toplam 192 adet EEG verisine ayırık dalgacık dönüşümü (ADD) uygulayarak travma derecesini belirlemektedir. Bu çalışma sonucunda geliştirilen metodun aynı zamanda hekimlerin değerlendirmesiyle %73,96 oranında benzerlik gösterdiği bulunmuştur ($p < 0.001$).

Toprak ve Çağlar yaptıkları çalışmada [11], epilepsi teşhisinin hızlı şekilde yapılabilmesi için EEG kayıtlarının otomatik olarak değerlendirilmesini amaçlamışlardır. Veri seti iki kümede oluşturulmuş ve gözleri açık sağlıklı kişilerden ve epilepsi krizi sırasındaki hastalardan alınan EEG sinyallerinden oluşmaktadır. Ayırık dalgacık dönüşümü yöntemiyle DB2 ve DB4 dalgacıkları alınıp çok katmanlı sinir ağları ile sınıflandırılmıştır. DB2 dalgacığı %99,62 oranında doğrulukla en yüksek sonucu vermiştir.

Farklı bir çalışmada [12], mutluluk kavramının eğitim alan ve almayan bireyler üzerindeki etkisi incelenmiştir. Eğitim alan bireylerde beynin sağ ve sol kanallarının EEG sinyalleri ile ne derece değiştiği konusu araştırılmıştır. Bu çalışmada, eğitim alan 18 birey, eğitim almayan 12 birey şeklinde iki küme oluşturulmuştur. Bu kümeler de dört aşama şeklinde incelenmiştir. İlk aşamada her iki grupta eğitim öncesi EEG sinyalleri alınmıştır. İkinci aşamada mutluluk kavramının eğitimi sonrası her iki küme EEG sinyal alımı, üçüncü aşamada ise ilk küme eğitim önce ve sonrası EEG sinyali elde edilmiştir. Son aşamada ise ilk kümenin sağ ve sol kanallarından eğitim öncesi ve

sonrası EEG sinyalleri alınmıştır. Sinyaller üzerine ayrık dalgacık dönüşümü (ADD) uygulanmıştır. Sınıflandırma için makine öğrenmesi yöntemlerinden Karar Ağacı, K-en yakın komşu, Naive Bayes ve Destek Vektör Makineleri kullanılmıştır. Sonuçlar kısmında, mutluluk eğitimi öncesi iki küme arasındaki sınıflandırma ile doğruluk oranı %63,3; mutluluk eğitimi sonrasında ise %78,3 bulunmuştur. Üçüncü aşamadaki sınıflandırma ile de %87,3 doğruluk oranı elde edilmiştir. Dördüncü ve son aşamada ise beynin sol yarım küresinin mutluluk kavramı açısından sağ yarım küreye göre daha baskın olduğu bulunmuştur.

Yöne bağlı olarak geliştirilen bir EEG sinyal analizi çalışmasında [13], 10 farklı erkek katılımcıdan iki boyutlu imlecin sağa, sola, yukarıya ve aşağıya hareket ettirmelerini düşünmeleri istenerek, imleç kontrolünün saklı yön bilgileri alınmıştır. Sinyallerin özellik çıkarımında istatistiksel parametreler olarak; ortalama sinyal gücü, varyans, entropi ve hjorth parametrelerine bakılmıştır. Boyut indirgemesi ve gürültü temizliği için temel bileşenler analizi (TBA) ve bağımsız bileşenler analizi kullanılmış; Fourier, kısa zamanlı Fourier dönüşümü, spektral güç yoğunluğu ve dalgacık dönüşümleri ile sinyaller analiz edilmiştir. Çıkan sinyal sonuçları makine öğrenmesi algoritmasından yararlanılarak sınıflandırılmıştır. En yüksek doğrulukla başarı oranı için beyin bilgisayar arayüz tasarımının en iyi yapı olduğu görülmüştür.

LabVIEW ile gerçekleştirdikleri çalışmalarında Sulaiman ve ark. [14], engelli kişilerin özellikle ileri, geri, sağ, sol ve durma hareket yönlerini bulması üzerine bir arayüz tasarımı yapmışlardır. Katılımcı 10 bireyden her bir hareketi 3 dakika boyunca düşünmeleri istenmiş, beyin sinyalleri LabVIEW ortamına aktarılmıştır. Burada hızlı Fourier dönüşümü uygulanarak sinyallerin 0,5-40 Hz arasında güç yoğunluğuna sahip oldukları hesaplanmıştır. Yoğunluğa göre yapılan sınıflandırmada arayüze giriş yapılmıştır. Arayüzde yönler için doğruluk oranı; ileri yönde %70, geri yönde %30, sağ yönde %20, sol yönde %20 ve durmada %50 olarak hesaplanmıştır.

Bu tez çalışması kapsamında, 41 sağlıklı erkek ve kadın katılımcının sağ ve sol yönleri düşünmeleri istenilmiş, Neurosky Mindwave Mobile 2 cihazı kullanılarak gözleri açık şekilde ölçümler alınmıştır. LabVIEW programındaki LabVIEW-Neurosky Driver BBA sayesinde gerçek zamanlı olarak EEG sinyalleri oluşturulan veri tabanına kaydedilmiştir. Veri tabanındaki EEG sinyallerinin detaylı zaman ve zaman-frekans analizleri yapılmıştır. Analiz aşamasında, ön işleme kısmında hatalı verilerin elimine edilmesi ve band geçiren filtre uygulanması ile sinyaller gürültüden temizlenmiştir.

Gürültüden temizlenen sinyallerinin ortalama, maksimum, entropi, güç, enerji, çarpıklık ve basıklık değerleri elde edilerek özellikler çıkartılmıştır. EEG ölçümlerinin analizinde ise Dalgacık Dönüşümü yöntemleri kullanılmıştır. Çalışmada sırasıyla, Topluluk Öğrenmesi (TÖ), Destek Vektör Makinesi (DVM), k En Yakın Komşuluk (k-NN) ve Karar Ağacı (KA) algoritmaları kullanılarak EEG sinyallerinin sağ ve sol yönlerdeki sınıflandırma performansları karşılaştırılmıştır.



2. BEYİN DALGASI SİNYALLERİNİN ELDE EDİLMESİ

Sinir sistemi 3 ana parçadan meydana gelir; duyuşal girdi kısmı, merkezi sinir sistemi ve motor çıktı kısmı. Merkezi sinir sistemi ise beyin ve omurilikten oluşur. Beyin bilgiyi depolar, düşünceler üretir, hırs yaratır ve vücudun duyuşlara tepki olarak gerçekleştirdiğı tepkileri belirler [15].

İnsan beyni sinirler ve omurilik beraberinde merkezi sinir sistemini denetler ve insan bedenindeki tüm görevleri yönetir. Kan dolaşımı, solunum, terleme gibi istemsiz faaliyetler beyinde bulunan otonom sinir sistemi sayesinde farkına varmadan beyin aracılığıyla idare edilir. Karar verme, araştırma, mantık, yön tayini, matematiksel işlemler gibi daha karmaşık zihinsel faaliyetler beyin tarafından bilinçli yönetilir [16].

Beyin; beyin sapı, limbik sistem ve neokorteks olmak üzere üç ana kısımdan oluşmaktadır.


Beyin Sapı: Omuriliğın tepesini kuşatan bölümdür. Solunum, kalp atışı, risk durumlarındaki istemsiz davranışlar gibi kalıplaşmış tepkileri yani yaşama dair esas faaliyetleri yönetir. Bu bölümde düşünme ve yeni öğrenme gerçekleşmez. Yaşamamız için gerekli olan tepkileri idare eden, önceden programlanmış bir düzenleyicidir. Başka bir deyişle içgüdüsel davranışlarımızın merkezidir.

Limbik Sistem: Beyin sapını kuşatan bölümdür. Duygularımızı yönetir. Amigdala ve hipotalamus bu bölünün iki esas kısmıdır. Uzun süreli belleğın önemli bir bölümü limbik sistem tarafından yönetilir. Bu nedenle duyuşal bağ kurduğumuz olayları daha hızlı anımsarız.

Neokorteks: Düşüncenin merkezidir. Görme, işitme, dil, yazma, plan yapma gibi yüksek zihinsel görevleri kontrol eder. Duyulardan algıladıkları sinyaller sayesinde bunları bir araya getirip anlamlandıran bölümdür. Neokortekste duyuşal verilerin büyük kısmı burada işlendiğinden, veri saklama için ayrı kısımları bulunur. Bu kısımlara lob denir. Konuşma, işitme, görme ve dokunma duyuşlarına ait sinyaller bu loblara ayrı ayrı kaydedilir.

Yarımkürelerin her biri de bölümlere (lob) ayrılmıştır. İnsan beyinde Şekil 2.1’de gösterildiği gibi beş ana lob vardır. Bu lobların görevleri;

- *Frontal lob*: Bilinçli düşünmeyi sağlar. Eğer zarar görürse bireyin ruhsal ve duygusal halinde varyasyon olabilir.
- *Parietal lob*: Duyu organlarından gelen verilerin entegresinde görevlidir. Objelerin kullanımında ve mekansal görüşte etkili olur.
- *Oksipital lob*: Bu lob görme ile alınan bilgileri işler. En ufak zararda bile görme kaybı oluşabilir.
- *Temporal lob*: Ses, koku, yer ve sima verilerini işlemektedir.
- *Serebellum lob*: Duyu organlarından gelen herhangi bir veriyi hareket ile ilişkilendirir. Bu da denge sağlamamıza yardımcı olmaktadır.



Şekil 2.1: Beyin lobları [17]

2.1 Beyin Dalgaları/ Elektroensefalografi (EEG)

Beynimizde bulunan nöronlar elektriksel ve kimyasal sinyaller ile bağlantı kurarlar. Beyin dalgaları ise beyindeki elektriksel aktivitelerin oluşturduğu ritmik ve tekrarlayıcı hareketlerdir. Elektroensefalografi (EEG) ise beyin dalgaları elektriksel aktivitelerinin izlenmesini sağlayan ölçüm yöntemidir. EEG sinyalleri ilk defa Richard Caton tarafından 1890 yılında tavşan ve maymun beyni üzerine yaptığı çalışmalar


neticesinde bulunmuştur. 1929 yılında ise Hans Berger tarafından ilk defa kaydedilmiştir.

EEG sinyallerinin kullanıldıkları yerleri aşağıdaki gibi sıralayabiliriz:

- Koma, uyanıklık ve beyin ölümünün takibinde,
- Kafa travması, inme, tümör gibi lezyonların teşhis ve takibinde,
- Duyusal sinirlerin test edilmesinde,
- Geri besleme üretilmesinde,
- Anestezi derinliğini kontrol etmede,
- Epilepsi, ensefalit ve ensefalopati ile giden hastalıkların tanısında, takibinde, araştırılmasında, yerinin tespit edilmesinde ve tedavileri sırasında kullanılan ilaçların etkisinin testinde,
- İnsan ve hayvan beyni gelişiminin takibinde,
- Uyku bozukluğunun ve fizyolojisinin araştırılmasında,
- Beyin Bilgisayar arayüz (BBA) sistemleri aracılığıyla objelerin ve uzuvların kontrol sistemlerinin geliştirilmesinde,
- Nöropazarlama ile geniş kitlelerin satın alma alışkanlıklarının incelenmesinde,
- Öğrenme, hafıza, dikkat, duygu tespiti gibi konularda kullanılmaktadır [18-19].


BBA tasarımları için anahtar kavram, frekans bandı bölütlemesidir. EEG sinyali, 0-60 Hz frekans bandı içindeki dalgalardan oluşur. Kaydedilen salınımların çıkarılan frekans içeriğine dayalı olarak farklı beyin aktiviteleri ve durumları tanımlanabilir. EEG sinyalinin ana frekans bantları aşağıdaki gibidir:

Delta dalgaları: 4 Hz'in altında frekansa sahiptir ve derin uyku ile ilişkilidir. Şekil 2.2'de de gösterildiği gibi yüksek genlikli, düşük frekanslı dalgalardır ve nöronlar tarafından işleme eksikliğinden üretilirler. Delta dalgaları, komadaki bir hastayı muayene ederken de bulunabilir.




Şekil 2.2: Örnek bir delta dalgası

Teta dalgaları: 4 Hz ile 8 Hz arasındaki frekanslara sahiptirler. Rüya benzeri durumlar ve eski anılar için tipiktir. Ancak aynı zamanda anksiyete, epilepsi ve travmatik beyin hasarı ile de ilişkilendirilebilir. Şekil 2.3'te örnek bir teta dalgası formu gösterilmiştir.




Şekil 2.3: Örnek bir teta dalgası

Alfa dalgaları: 8 Hz ile 13 Hz arasındaki frekanslara sahip sinyallerdir. Rahat bir durum, hafızaya kayıt ve eski anılara karşılık gelir. Oksipital beyin bölgesinde kaydedilen rahat bir duruma karşılık gelir. Alfa dalgalarının genliği 10 ile 50mV arasında değişir. Şekil 2.4'te örnek bir alfa dalgası formu gösterilmiştir.




Şekil 2.4: Örnek bir alfa dalgası

Beta dalgaları: 13 Hz ile 30 Hz arasındaki frekanslara sahip sinyallerdir. Uyanıklık, uyarılma, konsantrasyon ve dikkat ile ilişkilidir. Beta dalgaları hızlıdır ancak genliği düşüktür. Şekil 2.5'te örnek bir beta dalgası formu gösterilmiştir.



Şekil 2.5: Örnek bir beta dalgası

Gama dalgaları: 30 Hz ile 50Hz arasındaki frekanslara sahip sinyallerdir. Algılama, problem çözme ve yaratıcılık gibi zihinsel faaliyetler için karakteristik sinyallerdir. Şekil 2.6'da örnek bir gama dalgası formu gösterilmiştir.



Şekil 2.6: Örnek bir gama dalgası

Her belirli beyin aktivitesi için, daha önce belirtilen frekans bantlarından birinde daha güçlü elektriksel aktivite üreten belirli bir alan vardır. Benzer şekilde, iç artefaktlar kafa derisinin bazı kısımlarında diğerlerinden daha önemlidir. Sonuç olarak, her kanal belirli bir kafa derisi konumuna karşılık gelen EEG sinyalleri çok kanallı sinyallerdir. Kafa derisinin oksipital bölgesinin, görsel simülasyona ve görüntülerin algılanmasına yanıt olarak bantta daha güçlü elektrik sinyalleri sağladığı bilinmektedir [20].

3. İNCELENEN DALGACIK DÖNÜŞÜMÜ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ

Bu tez çalışmasında, EEG sinyallerin anlamlandırılmasında ve öznitelik çıkarımında istatistiksel yöntemler ve dalgacık dönüşüm yöntemleri kullanılmıştır.

3.1 Dalgacık Dönüşümü

Dalgacık dönüşümü, bir $f(t)$ sinyalinin, dalgacık adı verilen bir ana fonksiyonun $\psi(t)$ daralmaları, açılımlarından ve ötelemelerinden oluşan bir dizi temel fonksiyona ayrıştırılmasıdır. Yani sinyalin belirli dalgacık tarafından farklı ölçek bileşenlerine bölünmesidir. Aynı zamanda özel bir fonksiyonun belirli dalgacıklarla temsiline dalgacık dönüşümü de denir [21].

Dalgacık dönüşümü, sinyallerin yerel zaman-frekans analizi için kullanılan yöntemlerden biridir. İki türü mevcuttur. Sürekli dalgacık dönüşümü (SDD) ve ayrık dalgacık dönüşümü (ADD) şeklindedir.

Dalgacıklar, ana dalgacık olarak adlandırılan bir temel fonksiyondan ψ genleşmeleri ve ötelemeleri ile üretilen fonksiyonlardır. Dalgacıklar genellikle sınırlı süre, ortalama sıfır değeri, düzensiz ve asimetrik temel işlevler kümesidir [21]. Dalgacık analizi yapmamızın nedenlerini sıralarsak;

- Geleneksel sinyal işleme algoritmalarının dayandığı Fourier analizi, geçici sinyallerle iyi sonuç vermez.
- Dalgacık analizi, geçici sinyallerle iyi sonuç verir.
- Dalgacık algoritmaları gömülü sistemlerde kolaylıkla uygulanabilir.
- Dalgacık dönüşümü analizi, zaman ve frekans alanındaki bir sinyalin yerel niteliklerini belirleme yeteneğine sahiptir.
- Düşük frekanslarda yüksek doğruluğun gerekli olduğu genişletilmiş zaman aralıkları için uygundur ve bunun tersi de geçerlidir [21].

3.1.1 Sürekli Dalgacık Dönüşümü (SDD)

Dalgacık dönüşümü, zaman alanında tanımlanan bir fonksiyonun, zaman ölçeği gösterimi olan bir fonksiyona eşlenmesidir. Aslında dalgacık dönüşümü, tek boyutlu bir fonksiyonun iki boyutlu olarak temsilidir.

Dalgacık dönüşümünün aşağıdaki tanımında, $L^2(\mathbb{R})$, kare-integre edilebilir fonksiyonların uzayıdır.

$f(t)$, $t \in \mathbb{R}$ dönüştürülmesi gereken sinyal olsun, burada $f(\cdot) \in L^2(\mathbb{R})$. Yani;

$$\int_{-\infty}^{\infty} |f(t)|^2 dt < \infty. f(\cdot) \text{ fonksiyonunun dalgacık dönüşümü aşağıda tanımlanmıştır.}$$

Ana dalgacık fonksiyonunun $\psi(t)$, $t \in \mathbb{R}$ 'nin kaydırılması ve ölçeklenmesiyle hesaplanır. Burada $\psi(\cdot) \in L^2(\mathbb{R})$ şeklindedir.

Sürekli dalgacığın işlem adımları sıralanacak olursa:

1. Dönüştürülecek sinyal: $f(t) \in \mathbb{R}$, $t \in \mathbb{R}$ ve $f(\cdot) \in L^2(\mathbb{R})$.
2. $\psi : \mathbb{R} \rightarrow \mathbb{C}$ işlevi. Burada $\psi(\cdot) \in L^2(\mathbb{R})$, ana dalgacık veya prototip işlevi olarak adlandırılır.
 $\Psi(\cdot)$, $\psi(\cdot)$ 'nin Fourier dönüşümüdür. Yani, $\psi(t) \leftrightarrow \Psi(\omega)$.
 $\Psi(\cdot)$ fonksiyonu aşağıdaki koşulu da sağlamalıdır.

$$C_{\Psi} = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (3.1)$$

Bu ilişkiye kabul edilebilirlik koşulu da denilmektedir. Dalgacık dönüşümünden $f(t)$ 'yi kurtarmak için gereklidir.

3. $a, b \in \mathbb{R}$ ve $a \neq 0$ olsun.

$$\Psi_{a,b}(t) = \frac{1}{|a|} \Psi\left(\frac{t-b}{a}\right), \quad t \in \mathbb{R} \quad (3.2)$$

4. $f(\cdot)$ fonksiyonunun sürekli dalgacık dönüşümü aşağıdaki denklem 3.3'te verilmiştir [22].

$$W_f(\Psi, a, b) = \int_{-\infty}^{\infty} f(t) \overline{\Psi_{a,b}(t)} dt \quad (3.3)$$

3.1.2 Ayırık Dalgacık Dönüşümü (ADD)

Sürekli dalgacık dönüşümü, ana dalgacığın zaman düzleminde ötelenmiş ve ölçeklenmiş sürümleriyle çarpılan sinyalin, tüm zaman süresince toplamıdır [22].

Dalgacık katsayıları bu işlemlerden sonra ölçek ve konuma bağlı olarak çıkarılmaktadır. Eğer ölçekleme ve öteleme ikinin üsleri şeklinde yapılırsa, çözümlemeler sürekli dalgacığa göre daha etkili ve sürekli dalgacık dönüşümü gibi doğru sonuçlar verir. Bu çeşit çözümlemeye ayrık dalgacık dönüşümü denir. Ayrık dalgacık dönüşümünü elde etmek için kullanılan yöntemlerden bir tanesi çoklu çözünürlük analizi (ÇÇA)'dir. Ayrık işarete sırasıyla alçak geçiren ve yüksek geçiren filtreler uygulanmaktadır. EKG sinyallerinin zaman alanına ait öznitelikleri çıkarılabileceği gibi, frekans alanına ait de öznitelikler çıkartılıp sınıflandırma işlemi yapılabilmektedir. Fourier Dönüşümü ile durağan sinyallerde fazlasıyla uygun frekans çözünürlüğü bulunur. Ancak zaman, çözünürlüğü yok etmektedir. Zaman aralığında frekans birleşenlerinin hangisi olduğu Fourier yöntemi ile tespit edilemez. SDD'de çok fazla hesap adımları ve karmaşık hesaplar mevcuttur. Bu durumu iyileştirmek için ayrık dalgacık dönüşümü kullanılır. Durağan olmayan sinyallerde hangi zamanda hangi frekansın oluştuğunu bulmak önemlidir. Bu tür çalışmalarda frekans uzayı öznitelik çıkarımı için ADD metodu kullanılmaktadır. Dalgacık dönüşümü; veriyi diğer frekans bileşenlerine ayırır ve her bir bileşeni o ölçekteki çözünürlüğüyle inceler. Zamanın fonksiyonu olan bir işaretin dalgacık dönüşümü, frekans ve zaman değişkenlerine bağlıdır. Dalgacıklar zaman frekans analizi için iyi bir aracılık sağlar. ADD ilgili denklemler aşağıda verilmiştir [22].

$$d(m,n) = \int_{-\infty}^{\infty} f(t) \overline{\Psi_{mn}(t)} dt, \quad \forall m,n \in Z \quad (3.4)$$


$$\Psi_{mn}(t) = a_0^{m/2} \Psi(a_0^m t - nb_0), \quad \forall m,n \in Z \quad (3.5)$$

Bu tez çalışmasında, dalgacık dönüşümü yönteminden elde edilen öz niteliklerin değerlendirilmesinde aşağıdaki sınıflandırıcı yöntemleri denenmiş ve en iyi doğruluk sonuçları için test edilmiştir.

3.2 Destek Vektör Makineleri (DVM)

Makine öğrenmesinde denetimli öğrenme modeli olan destek vektör makineleri, sınıflandırma ve regresyon analizi için verileri analiz eden yöntemlerden biridir. Bu yöntem Vladimir Vapnik ve arkadaşları tarafından keşfedilen yüksek tahmin yöntemlerinden biridir [23].

Aynı zamanda istatistikte parametrik olmayan yöntemler olarak adlandırılır. DVM’de amaç iki sınıfı birbirinden ayıran optimal hiper düzlemi oluşturmaktır. Hiper düzlem ne kadar genişse o kadar daha iyi sınıflandırma yapılabilir. Şekil 3.1’de iki boyutlu örnek alanı için çizilen hiper düzlem gösterilmiştir.



Şekil 3.1: İki boyutlu örnek uzaylı geniş marjlı hiper düzlemi

DVM’nin doğrusal ve doğrusal olmayan olarak iki türü vardır.

Doğrusal veri kümesi; $(x_1, y_1), (x_2, y_2), (x_l, y_l), x \in R^n, y \in \{+1, -1\}$ şeklinde eğitim seti olarak belirtilirse hiper düzlem denklemi aşağıdaki gibidir.

$$d(x_p, w, b) > 0 \text{ ise } x_p \text{ class1 (i.e., } y_1 = +1) \quad (3.6)$$

$$d(x_p, w, b) < 0 \text{ ise } x_p \text{ class2 (i.e., } y_2 = -1) \quad (3.7)$$

$$d(x, w, b) = w^T x + b = \sum_{i=1}^n w_i x_i + b \quad (3.8)$$

Burada w ’ye ağırlık vektörü, b ’ye ayırtaç/karar değeri denilmektedir. Eğitim setinde bulunan tüm veriler için bu eşitlik, denklem 3.6, 3.7 ve 3.8’ deki koşulları sağlıyorsa, eğitim seti verileri doğrusal olarak ayrılabilir.

Doğrusal olmayan veri kümesinde doğrusal hiper düzlemi çizilemez. Bu nedenle kernel (çekirdek) yöntemi kullanılır. Çekirdek fonksiyonunda değer verilerek hiper düzlemi oluşturulmakta ve veri kümesinin iki sınıfa ayrılması sağlanmaktadır [24].

3.3 En Yakın k Komşuluğu Algoritması (k-NN)

İlk olarak 1950’li yıllarda ortaya çıkan, denetimli öğrenme yöntemlerinden biri olan k En Yakın Komşu algoritması hem sınıflama hem de regresyon ayağında kullanılabilen çok yönlü bir algoritmadır. k-nearest neighbors (k-NN) olarak ta bilinen yöntemde, eğitim setindeki veriler etiketlere böldüğümüz sınıflara atanmaktadır. Bunun için veri uzayındaki benzerliklerine bakılmaktadır. k-NN için algoritma adımları yazılacak olursa:

- K parametresi belirlenir. K verilen bir noktaya en yakın komşuların sayısıdır.
- Algoritma uzaklık fonksiyonu temsil eder. Yeni verilerin önceki verilere göre uzaklığını hesaplar.
- Uzaklıkların özniteliğine göre en yakın K komşu veya komşularına atanır.
- Yeni veri böylece sınıflandırılmış/etiketlenmiş olur.

Rasyonel sayılar kümesinde $p = 2$ için Öklid mesafesine karşılık gelen Minkowski metriğini (p-norm) kullanmak mantıklıdır. Bu ifade denklem 3.9’da gösterilmiştir.

$$\|x' - x_j\|^p = \left(\sum_{i=1}^q (|(x_i)' - (x_i)_j|)^p \right)^{1/p} \quad (3.9)$$

İkili sınıflandırma durumunda, $Y = \{1, -1\}$ etiket kümesi kullanılır ve k-NN, komşuluk boyutu k ile ve k-en yakın modellerin $N_{k(x')}$ endeksleri kümesiyle tanımlanır. Bu fonksiyon denklem 3.10’da verilmiştir [25].

$$f_{kNN}(x') = \begin{cases} 1, & \sum_{i \in N_{k(x')}} y_i \geq 0 \\ -1, & \sum_{i \in N_{k(x')}} y_i < 0 \end{cases} \quad (3.10)$$

Birçok örnekler arası uzaklık hesaplama türü vardır. Bunlar; Minkowski, Öklid, Manhattan, Chebyshev vb. olarak sıralanabilir. k-NN yöntemi, eski, basit ve gürültülü eğitim verilerine karşı dirençlidir. Bu yüzden yaygın olarak kullanılan makine öğrenme algoritmalarından biridir. Fakat bunun yanında dezavantajları da vardır. Mesela, uzaklık hesabı yaparken bütün durumları saklar ve bundan dolayı, büyük veriler için kullanılırken fazla sayıda bellek alanına ihtiyaç duymaktadır. k-NN algoritmasının bir özelliği de, verilerin yerel yapısına duyarlı olmasıdır.

3.4 Karar Ağacı Algoritması (KA)

Veri madenciliğinde karar ağacı algoritması, sınıflandırılmaları temsil etmek için kullanılabilecek tahmine dayalı bir modeldir. Aynı zamanda regresyon modellerinde de kullanılabilmektedir. Sınıflandırma ağaçları, bir nesneyi nitelik değerlerine dayanarak önceden tanımlanmış bir sınıflar kümesine sınıflandırmak için kullanılır. Sınıflandırma ağaçları hiyerarşik yapılar olarak grafiksel olarak temsil edilir. Bu da bulunan verilerin yorumlanmasının diğer tekniklere göre daha kolay okunmasını sağlar. Karar ağacının kullanılması, sade ve şeffaflık sağlaması sebebiyle veri madenciliğinde çok popüler bir tekniktir. Sınıflandırma ağaçları özellikle mühendislik başta olmak üzere; finans, istatistik ve tıp gibi diğer uygulamalı alanlarda da sıklıkla kullanılmaktadır.

KA algoritmasının işlem adımları sıralanacak olursa:

- 1) Verilerin nitelikleri içerisinde en iyi ayıran öznitelikleri belirlenir. Belirlenen öznitelikler ile ağaçların düğümleri oluşturulur.
- 2) Oluşturulan düğümlerden, alt düğümler ve yapraklar oluşturulur. Böylece ağacın dalları oluşur ve entropi yöntemine göre dizilir.
- 3) Alt düğüm var ise bu düğümlere ait veri kümesinin örnekleri belirlenir. Alt düğüm yok ise süreç sonlandırılır.
- 4) İkinci maddeye dönülür.

Sınıflandırma ağacı karmaşık hale gelirse (yani birçok düğümü varsa), o zaman basit grafik gösterimi işe yaramaz hale gelir. Bu sebepler diğer sınıflandırma modelleri tercih edilmelidir [26].


3.5 Topluluk/Kolektif Öğrenme (TÖ)

Bir topluluk, temel öğrenenler olarak adlandırılan bir dizi öğrenci içerir. Temel öğrenenler genellikle eğitim verilerinden karar ağacı, sinir ağı veya diğer tür öğrenme algoritmaları olabilen bir temel öğrenme algoritması tarafından üretilir.

Topluluk öğrenmesinin (TÖ) yöntemlerinin çoğu, homojen temel öğrenenler, yani aynı tipte öğrenenler, homojen topluluklar oluşturan öğrenciler üretmek için tek bir temel öğrenme algoritması kullanır. Ancak heterojen öğrenenler, yani farklı türlerde öğrenenler üretmek için çoklu öğrenme algoritmaları kullanan bazı yöntemler de vardır. Aslında, topluluk yöntemleri çekicidir. Çünkü rastgele tahminden biraz daha iyi olan zayıf öğrencileri, çok doğru tahminler yapabilen güçlü öğrenciler ile

destekleyebilirler. Bu nedenle, temel öğrenenler aynı zamanda zayıf öğrenenler olarak da adlandırılır [27].

Şekil 3.2’de topluluk öğrenme metodu kullanarak çeşitlilik azaltımı gösterilmiştir.



Şekil 3.2: Topluluk öğrenme metodu kullanarak çeşitlilik azaltımı

Etkili bir topluluk sistemi için üç aşama olmalıdır:


- 1) Veri seçimi,
- 2) Üye sınıflandırıcılarını eğitmek,
- 3) Sınıflandırıcıları birleştirmek [27].

En çok kullanılan topluluk öğrenme algoritmaları; Bagging, Boosting, AdaBoost, Stacked Generalization ve Mixture of Experts’dir.

3.6 k-Katlı Çapraz Doğrulama (k-Fold Cross Validation)

Genellikle sınıflandırma yapılırken en çok yaşanan sorun aşırı uyumdur (overfitting). Aşırı uyum, veri setindeki eğitim verilerini her katmanda daha iyi öğrenmeye devam ettiği halde, test verileri üzerindeki performansın hiç iyileşmediği anlamına

gelmektedir. Makine öğrenimi modelleri oluşturmak için bir veri kümesi alındığında, bunlar eğitim ve doğrulama şeklinde iki farklı kümeye ayrılmaktadır. Bu veriler birbirinden ayrı, k farklı kümeye bölünmektedir. Bu yöntem Şekil 3.3'te gösterildiği gibi k-katlı çapraz doğrulama denilmektedir [28].



Şekil 3.3: k-Katlı çapraz doğrulama


k-katlı çapraz doğrulamadaki k parametresini seçerken, uygun kutu sayısını hesaplamak için denklem 3.11'deki Sturge Kuralı kullanılmaktadır. Denklemdeki N, veri kümesindeki sahip olunan örnek sayısıdır.

$$Number\ of\ Bins = 1 + \log_2(N) \quad (3.11)$$

Çapraz doğrulama, genellikle büyük miktarda veri seti ve model çıkarmanın çok zaman aldığı süreçlerin olduğu durumlarda kullanılmaktadır. Bu doğrulamada en çok kullanılan türler; k-fold cross-validation, stratified k-fold cross-validation, hold-out based validation, leave-one-out cross-validation ve group k-fold cross-validation'dır.

4. ÖNERİLEN YÖNTEMLER


Bu tez çalışmasında, öncelikle gerçekleştirilen deneyler ile EEG ölçüm cihazından alınan sinyaller sayesinde bir veri seti oluşturulmuş, bu veriler üzerinde dalgacık dönüşümü yöntemleri uygulanıp öznitelik çıkarımı yapılmış, daha sonra da bu öznitelikler ile en yüksek doğruluğu sağlayabilecek sınıflandırıcıların performansları incelenmiştir. Bu incelemeler ile en iyi doğruluk oranını sağlayan öznitelik çıkarıcı ve sınıflandırıcının, yani hibrit makine öğrenme yönteminin belirlenmesi amaçlanmıştır. Deneysel çalışmada, bireylerden Neurosky mindwave 2 cihazıyla EEG sinyalleri okunmuştur. Ardından LabVIEW ile entegre olan BBA arayüzünden veriler alınmıştır. Daha sonra alınan verilere Matlab ortamında ön işlem yapılmıştır. Filtre uygulandıktan sonra öznitelik çıkarımı yapıp, son olarak sınıflandırma yapılmıştır. Bu akış Şekil 4.1’de ayrıntılı olarak gösterilmiştir.



Şekil 4.1: Çalışmanın ana akış şeması

Yaptığımız çalışmada, sinyaller ilk önce literatürdeki örneklere göre anlamlı olan alfa ve beta dalgaları olarak belirlenen 8 Hz ile 30 Hz aralığı alınmıştır. Bu frekans bandının altındaki ve üstündeki değerler filtrelenmiştir. Verilere ilk önce hızlı Fourier dönüşümü uygulanmıştır. Literatürdeki bilgilere de bakarsak, bu durum bize herhangi anlamlı sonuç vermemiştir. Diğer taraftan 8 Hz ile 30 Hz aralığındaki dalgalar, bant

geçiren filtre sayesinde alfa (8-13 Hz) ve beta (13-30 Hz) dalgaları olmak üzere iki sınıfa ayrılmıştır. Burada normalizasyon işlemi uygulanmıştır. Dalgacık dönüşümü yapıldıktan sonra EEG sinyalleri için literatürdeki tavsiye edilen istatistiksel analizler ile en anlamlı özellikler çıkarılmıştır. Daha sonra elde edilen öznitelikler sınıflandırıcıya sokulmuştur. Sağ(0) ve sol(1) olarak sınıflandırma doğruluk oranlarına bakılmıştır. Sonraki aşama olarak sınıflandırılmış veri, dezenfeksiyon cihazının yönlendirilmesi için kullanılmaktadır. Şekil 4.2’de çalışmanın detaylı akış şeması gösterilmiştir.




Şekil 4.2: Çalışmanın detaylı akış şeması

4.1 EEG sinyallerin Alınması & Veri Setinin Oluşturulması

EEG cihazından veri alımı, Ottonom Mühendislik Çözümler Ar-ge Merkezi’nde gerçekleştirilmiştir. Deneyin yapılacağı günün öncesinde katılımcılara bilgilendirilme yapıldı, ortamın her katılımcı için aynı çevresel özelliklerde olması sağlanmıştır. Bu çalışmada kullanılan veriler, 41 farklı katılımcıdan sağlanmıştır. Tüm katılımcıların veri alımı bir gün içinde, sessiz ortamda ve dikkat dağınıklığı bozacak nesnelerin kaldırılmasıyla yapılmıştır. Katılımcılar verinin alınacağı salona geldiklerinde hatırlatıcı niteliğinde tekrar bilgilendirme yapılmıştır. Katılımcıların her birinin önceden rızası alınmıştır. Ardından kişilere Neurosky cihazının bir kolu alnın tam ortasına (sinyalin okunduğu bölge), diğeri ise kulak memesine (topraklama yapıldığı bölge) takılmıştır. Katılımcılar hazır hissettiğinde veri alımına başlanılmıştır. Katılımcıların önlerine oyuncak araç konularak (böylece daha kolay konsantre olunması amaçlanmıştır) aracın 1 dakika boyunca sağa döndüğünün düşünülmesi

istenmiştir. Ardından katılımcıların aracın sola döndüğünü 1 dakika boyunca hayal etmesi istenilmiştir. Bu döngü her katılımcı için yapılmıştır. Ölçümler katılımcıların ergonomik bir sandalyeye oturması sağlanarak alınmıştır. Ölçüm alınırken, oda sıcaklığı 20-24 °C aralığında sabit tutulmaya çalışılmış ve odanın ışık seviyesinin olabildiğince gözü almaması sağlanmıştır. Toplam deney süresi ortalama 2 dakika olarak hesaplanmıştır. Ancak EEG cihazının yerleştirilmesi, katılımcıların odaklanması ve plansız gerçekleşen durumları da hesaba katarsak ölçüm süresi 3-4 dk arasında değişmektedir. Alınan veri ortamı Şekil 4.3'te gösterilmiştir.




Şekil 4.3: EEG sinyallerden Neurosky cihazı ile veri alınımı

Veri paketi yaş aralığı, 23 yaş ile 61 yaş arasında değişmekte olan sağlıklı bireylerden alınmıştır. Veriler, Şekil 4.4'te gösterildiği gibi Neurosky mindwave mobile 2 cihazıyla alınmıştır. Cihaz kuru elektrot sayesinde herhangi bir ek işleme tabi tutulmadan kişilerden veri alımını sağlamaktadır. Cihaz verileri 16 bitlik ve saniyede 512 Hz frekansında kayıt yapmaktadır. Bu çalışmada 1 dk'lık sağ ve 1 dk'lık sol olmak üzere toplamda 2 dk'lık veriler alınmıştır. Bu sebeple sadece sağ veya sadece sol taraf, 1 kişi için 30720 veri içermektedir.



Şekil 4.4: Neurosky cihazı

Verilerin elde edilme yöntemi Şekil 4.5'te gösterilen LabVIEW-neurosky arayüzü kullanılarak yapılmıştır. Çizelge 4.1'de örnek veri çıkışı gösterilmiştir [29].



Şekil 4.5: LabVIEW-Neurosky arayüzü [29]

Çizelge 4.1: Ham EEG sinyal verilerinin ilk on satırı

Uzantılı Kod Seviyesi	Kod	16-bit İşaretili Değerler
1640110004.288:	[80]	-198, FF3A, -4.161290
1640110004.302:	[80]	-167, FF59, -3.979472
1640110004.303:	[80]	-92, FFA4, -3.539589
1640110004.304:	[80]	-23, FFE9, -3.134897
1640110004.305:	[80]	0, 0000, -3.000000
1640110004.308:	[80]	-17, FFEF, -3.099707
1640110004.308:	[02]	51
1640110004.308:	[83]	251533, 0x0003D68D
1640110004.308:	[04]	63
1640110004.308:	[05]	17

Çizelge 4.1'de görüldüğü üzere, bazı verilerde düzensizlikler mevcuttur. Bu verilere kişilere bağlı olduğundan, o sırada kişilerde sinyal alımında düşüklük, kopukluk, pil zayıflığı veya göz kırpması vb. artefaktlar olduysa, Çizelge 4.1'de görüldüğü gibi veri çıkışı olmaktadır. Anlamsız ve veri akışını bozan veriler Matlab tabanında kod


yazılarak çıkartılmıştır. Çizelge 4.2’de görüldüğü üzere eşit sayıda anlamlı veriler ile analize devam edilmiştir.

Çizelge 4.2: Düzenlenmiş EEG sinyali verilerinin ilk on satırı

Uzantılı Kod Seviyesi	Kod	16-bit İşaretli Değerler
1640699568.467:	[80]	53, 0035, -2.689150
1640699568.470:	[80]	62, 003E, -2.636364
1640699568.471:	[80]	50, 0032, -2.706745
1640699568.474:	[80]	36, 0024, -2.788856
1640699568.475:	[80]	35, 0023, -2.794721
1640699568.477:	[80]	44, 002C, -2.741935
1640699568.478:	[80]	49, 0031, -2.712610
1640699568.481:	[80]	66, 0042, -2.612903
1640699568.482:	[80]	89, 0059, -2.478006
1640699568.484:	[80]	106, 006A, -2.378299

4.2 Öznitelik Çıkarımı

Bu çalışmada sürekli ve ayrık dalgacık dönüşümü kullanılarak öznitelik çıkarımı yapılması amaçlanmıştır. Şekil 4.6’da öznitelik çıkarımı için izlenen süreç gösterilmiştir.



Şekil 4.6: Hata tespit, öznitelik ve sınıflandırma algoritması blok diyagramı

4.2.1 Sürekli dalgacık dönüşümü ile öznitelik çıkarımı

Anlamlı veriler ilk önce Matlab arayüzünde yazılan kodlar ile normalize edilmiş, ardından band geçiren filtreye sokularak Sürekli Dalgacık Dönüşümü (SDD) uygulanmıştır. İstatiksel yöntem olarak; Ortalama (denklem 3.12), Maksimum, Entropi (denklem 3.13), Güç (denklem 3.14), Enerji (denklem 3.15), Çarpıklık

(denklem 3.16) ve Basıklık (denklem 3.17) performans ölçütleri ele alınıp veri sonuçlarına bakılmıştır.

$$Ortalama = \frac{1}{N} * \sum_{L=1}^N |yp - yc| \quad (3.12)$$

$$Entropi = - \sum_{i=1}^N p(X_i) \log p(X_i) |yp - yc| \quad (3.13)$$

$$Güç = \int_{-\infty}^{\infty} R_x(\tau) e^{-j2\pi f\tau} d\tau \quad (3.14)$$


$$Enerji = \sum_{n=1}^N X_n^2 / N \quad (3.15)$$

$$\text{Çarpıklık} = \frac{\sum_{i=1}^N ((Y_i - \bar{Y})^3) / N}{s^3} \quad (3.16)$$

$$\text{Basıklık} = \frac{\sum_{i=1}^N ((Y_i - \bar{Y})^4) / N}{s^4} \quad (3.17)$$

4.2.2 Ayrık dalgacık dönüşümü ile öznelilik çıkarımı


Ayrık Dalgacık Dönüşümünde (ADD) ise veriler filtrelenerek gürültülerden ayrıştırılmıştır. Burada sinyaller Gama, Beta, Alfa, Delta ve Teta şeklinde 5 sınıfa bölünmüştür. Sol Sinyal için çıkan sonuçlar Şekil 4.7’de gösterilmiştir.



Şekil 4.7: Ayrık dalgacık dönüştürücü EEG sol sinyal verileri

4.3 Eğitim Verileri için Model geliştirme

Bu çalışmada, EEG sinyallerini anlamlandırmak için Sürekli Dalgacık Dönüşümü (SDD) ve Ayrık Dalgacık Dönüşümü (ADD) olmak üzere iki farklı model test edilmiştir. Modelleri geliştirmek için Matlab programlama dili kullanılmış olup, model diyagramı Şekil 4.8’de verilmiştir.




Şekil 4.8: SDD-ADD modelinin eğitim veri modeli süreç diyagramı

4.4 Sınıflandırma

Sınıflandırma için bilimsel araştırmalarda EEG verileri için anlamlı sonuçlar çıkaran ve aynı zamanda en çok kullanılan gözetimli öğrenme yöntemleri olan DVM, k-NN, KA ve TÖ yöntemleri seçilmiştir. Doğrulama yöntemi olarak, literatürde yaygın olan ve sistemin daha etkin öğrenimini sağlayan k-katlı çapraz doğrulama algoritması kullanılmıştır.

4.4.1 k-katlı çapraz doğrulama

Eğitim veri seti çıkışları test ve sınıflandırma yapılması için Matlab içerisinde yer alan IRIS arayüzüne yüklenmiştir. Model diyagramı Şekil 4.9’da verilmiştir.



Şekil 4.9: Sınıflandırma modelinin rapor süreç diyagramı

5. SONUÇLAR


Sınıflandırmada k katlı çapraz doğrulama kullanılmıştır. k parametresi Sturge Kuralı'na göre 10 seçilmiştir. Çizelge 5.1'de denenen tüm yöntemler gösterilmiştir. En iyi tahmin eden yöntemler, Topluluk Öğrenmesi (TÖ) ve Karar Ağacı (KA) yöntemleri olmuştur.

Çizelge 5.1: Tez kapsamında denenen yöntemler ve sonuçları


Sıra No	Kullanılan Yöntem	Sınıflandırıcı	Başarı Oranı
1	SDD	k-NN	%85
2	SDD	DVM	%82
3	SDD	KA	%84
4	SDD	TÖ	%95
5	ADD	k-NN	%51
6	ADD	DVM	%48
7	ADD	KA	%83
8	ADD	TÖ	%79
9	Yapay Sinir Ağları	k-NN	%60
10	Yapay Sinir Ağları	DVM	%42
11	Yapay Sinir Ağları	KA	%51
12	Yapay Sinir Ağları	TÖ	%63

5.1 Sürekli Dalgacık Dönüşümü (SDD) ve Topluluk Öğrenmesi (TÖ) Hibrit Makine Öğrenmesi Yöntemi

Çalışmada veri seti 10 parçaya bölünmüş ve her parça test verisi, kalan 9 parça eğitim verisi olarak kullanılmıştır. Çıkan veri setine TÖ ile sınıflandırma yapılmıştır. Doğruluk oranı en yüksek %95 çıkmıştır. Önerilen hibrit makine öğrenmesi yöntemi ile elde edilen sonuçlar Şekil 5.1 ve Şekil 5.2'de gösterilmiştir. Ayrıca diğer sınıflandırma araçları ile çıkan doğruluk sonuçları da Şekil 5.1'de ayrıntılı şekilde gösterilmiştir. Burada kullanılan arayüzde Boğaziçi ve Acıbadem üniversitesi iş birliği tarafından geliştirilen açık kaynak kodundan yararlanılmıştır. [30]



Şekil 5.1: SDD ve TÖ kullanılarak geliştirilen hibrit makine öğrenmesi yöntemi



Şekil 5.2: SDD ve TÖ hibrit makine öğrenmesi yönteminin doğruluk, özgüllük ve duyarlılık grafiği

Ayrıca Şekil 5.2’de gösterildiği gibi Özgüllük (specificity) %96 ve duyarlılık (sensitivity) %95 olarak bulunmuştur.


Hata matrisi (Confusion Matrix) ise Çizelge 5.1’de gösterilmiştir. Toplam 82 veriden 78’si doğru, 4 adedi yanlış tahmin edilmiştir.

Çizelge 5.2: TÖ ile sınıflandırmaki hata matris sonuçları


Confusion Matrix		Tahmin	
		<i>Sol</i>	<i>Sağ</i>
Gerçek	<i>Sol</i>	78	4
	<i>Sağ</i>	4	78
Toplam		82	82

5.2 Ayırık Dalgacık Dönüşümü (ADD) ve Karar Ağacı (KA) Hibrit Makine Öğrenmesi Yöntemi

Ayrık Dalgacık Dönüşümü ile eğitim verileri eğitildiğinde en yüksek oran Karar Ağacı ile %83’e ulaşmaktadır. Diğer sınıflandırma sonuçları ise Şekil 5.3’te gösterilmiştir. Şekil 5.4’ten, Özgüllük (specificity) %85 ve duyarlılık (sensitivitiy) %83 olarak bulunduğu gösterilmiştir.




Şekil 5.3: ADD ve KA kullanılarak geliştirilen hibrit makine öğrenmesi yöntemi



Şekil 5.4: ADD ve KA kullanılarak geliştirilen yöntemin doğruluk, özgüllük ve duyarlılık grafiği


5.3 Sinyal Sınıflandırma Arayüzü

Çalışma kapsamında sağ ve sol tahminleme için Matlab GUI ile beyin bilgisayar arayüzü (BBA) tasarlanılmıştır. Şekil 5.5'te gösterildiği gibi alınan EEG sinyali text biçiminde GUI arayüzünde seçilerek, ayırık dalgacık dönüşümü yapılmış ve sınıflandırma modeli seçilmiştir.



Şekil 5.5: Geliştirilen MATLAB GUI arayüzü

Sınıflandırma butonuna basıldığında, Şekil 5.6’da gösterildiği üzere sağ veya sol butonu yeşile dönerek doğru sınıf belirlenmektedir. Ayrıca “features” yazan kısımda öznelik çıkarımında bahsettiğimiz istatistiksel değerlerin sonuçları verilmektedir. Buradan da hangi yöntemin anlamlı olduğu gösterilmektedir.



Şekil 5.6: Sınıflandırılan MATLAB GUI örneği

6. TARTIŞMA

Bu çalışmada, insansız bir kara aracının (İKA) sağ ve sol yön tahmini için makine öğrenmesi sınıflandırma araçları ve dalgacık dönüşümüyle EEG sinyallerin anlamlı şekilde otomatik kontrolüne çalışılmıştır. Gerçekleştirilen çalışmalarda, önerilen hibrit makine öğrenmesi yöntemi ile %95'e varan doğrulukta tahmin yapılabilmektedir. Veri seti ilk defa bu tez çalışması kapsamında oluşturulmuştur. Veri seti kişi sayısının artmasıyla doğruluk oranının arttığını göstermektedir. Düşük maliyetli ve zaman kaybı olmadan verilerin alınarak İKA'nın otomatik kontrolünün yapılması, uygulama açısından önemlidir. Şekil 6.1'de görülen dezenfeksiyon cihazının EEG sinyalleri ile yön tahmini yapılması için ilk kilometre taşını oluşturmaktadır.

Daha fazla bireyden veri alınması, daha çok cihaz üzerinde denemelerin yapılması ile mevcut sistem daha da geliştirilebilir. Bireylerden veri alımı yapılırken bireylerin düşünme kalibrasyonu da yapılmalıdır. Yani bir bireyin sağ yönü doğrudan düşünmesi istenip bu şekilde veri alımı yapılmaktansa; bireyin ilk önce sağ, sonra sol, daha sonra sağ şeklinde ritmik ve tekrarlayıcı ilk 5 saniye kalibre yapıp daha sonra gerçek veri toplanmalıdır. Tez çalışmamızda bu tip hususlar kısıtlarımızı oluşturmaktadır.

Bu çalışmada, sanayide kullanılması planlanan örnek bir dezenfeksiyon cihazı için hazır bir veri seti ve iki farklı hibrit makine öğrenmesi yöntemi sunulmaktadır. Geliştirilen yöntemler ile gelecekte özellikle insanın olmaması gereken Covid-19'lu ortamlar gibi riskli alanlarda, bu tip giyilebilir cihazlardan alınan sinyallerle İKA vb. sistemlerin otomatik kontrolünün yapılabilmesine imkan sağlanmaktadır. Özellikle uygulamanın hastaneler, alışveriş merkezleri, okullar vb. kapalı mekanlarda kullanılması öngörülmektedir. Tez kapsamında geliştirilen sistemin cihaza entegre edilerek Ottonom Mühendislik Çözümleri A.Ş. tarafından geliştirilen ve Şekil 6.1'de gösterilen dezenfeksiyon cihazına entegre edilerek sanayide uygulanması da hedeflenmektedir.




Şekil 6.1: LUXIO Cihazı

KAYNAKLAR

- [1] Mischenko, Y. & Yıldız, Z. (2019). Elektroensefalografi Beyin-Makine Arayüzlerinin Gelişimi, *Türk Bilim Araştırma Vakfı*, 4 (12),1-15.
- [2] Toprak, İ., Caglar, M. & Merdan, M. (2007). Dalgacık Dönüşümü ve Bulanık Mantık Sistemine Dayalı Uyarlanırlı Ağ ile Epilepsi Hastalığı Teşhisi, *Süleyman Demirel Üniversitesi 15.Yıl Mühendislik Mimarlık Sempozyumu*, Isparta, Türkiye: Kasım 14-16.
- [3] Rabcan, J., Zaitseva, E. & Levashenko, V. (2018). Electroencephalogram Signals Analysis by Fuzzy Classifiers based on Cumulative Mutual Information, *14th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, Lviv-Slavske, Ukraine: February 20-24.
- [4] Güler, İ. & Übeyli, E. D. (2005). Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients, *Journal of Neuroscience Methods*, 148,113-121.
- [5] Çiğ, H. (2017). *EEG sinyalleri ile cihaz kontrolü*. (Yüksek Lisans Tezi). İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya.
- [6] Emhan, Ö. (2017). *Yukarı – aşağı imleç hareketine ilişkin EEG kayıtlarının ayrık dalgacık, knn ve dvm ile sınıflandırılması*. (Yüksek Lisans Tezi). Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Diyarbakır.
- [7] Çetin, E. (2020). *Mobil eeg tabanlı açlık ve tokluk sınıflandırılması*. (Yüksek Lisans Tezi). Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Antalya.
- [8] Yılmaz, F. M. (2021). *EEG sinyalleri ile epilepsi krizinin tahminlenmesinde rassal orman algoritması ile hiper parametre optimizasyonun uygulanması*. (Yüksek Lisans Tezi). İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [9] Ibrahim, M. S., Kamat, S. R., Shamsuddin, S., Isa M. H. M. & Ito, M. (2022). Electroencephalogram (EEG)-based Systems to Monitor Driver Fatigue: A Review, *International Journal of Nanoelectronics and Materials*,15, 365-380.
- [10] Demir, Ö. (2008). *EEG dalgalarının wavelet (dalgacık) dönüşümü ile değerlendirilmesi*. (Yüksek Lisans Tezi). Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya.
- [11] Toprak, İ., Caglar, M. & Merdan, M. (2007). Automatic Recognition of Epilepsy from EEG using Artificial Neural Network and Discrete Wavelet Transform, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, Isparta, Türkiye.
- [12] Saymaz, A. (2020) *Mutluluk eğitiminin eeg sinyalleri üzerine etkisinin makine öğrenmesi yöntemleriyle değerlendirilmesi*. (Yüksek Lisans Tezi). İstanbul Üniversitesi, Cerrahpaşa Lisansüstü Eğitim Enstitüsü, İstanbul.
- [13] Başçıl, M. S. (2015) *Beyinde üretilen yöne bağlı eeg sinyallerinin öznitelik çıkarımı yardımıyla sınıflandırılması*. (Doktora Tezi). Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.

- [14] **Sulaiman, N., Hau, C. C., Hadi, A. A., Mustafa M. & Jadin, S.** (2014). Interpretation of human thought using EEG signals and LabVIEW, *International Conference on Control System, Computing and Engineering (ICCSCE)*, Penang, Malaysia: November 28-30.
- [15] **Hall, J. E. P. & Hall, M. E.** (2020). *Textbook Of Medical Physiology*. ABD.: Elsevier.
- [16] **Url-1** < <https://www.beyin.gen.tr/>>, erişim tarihi 13.06.2022.
- [17] **Url-2** < <https://bilimgenc.tubitak.gov.tr/makale/insan-beyninin-yapisi-nasildir> >, erişim tarihi 13.06.2022.
- [18] **Bora, İ.** (2012). EEG Atlası. İstanbul: Nobel Tıp Kitabevleri.
- [19] **Teplan, M.** (2002). Fundamentals of EEG measurement. *Measurement Science Review*, 2(2), 1-11.
- [20] **Georgieva, P., Silva, F., Milanova, M., and Kasabov, N.** (2014). EEG Signal Processing for Brain–Computer Interfaces. *In Springer Handbook of Bio-/Neuroinformatics*, 797-812.
- [21] **Cajetan, M. A.** (2022). Wavelets and Wavelet Transform Systems and Their Applications. USA. Springer.
- [22] **Bhatnagar, N.** (2020). Introduction to Wavelet Transforms. USA. CRC Press.
- [23] **Cortes, C. & Vapnik, V.** (1995). Support Vector Networks. *Machine Learning*, 20, 273-297.
- [24] **Wang, L.** (2005). Support Vector Machines: Theory and Applications. Netherlands. Springer-Verlag Berlin Heidelberg.
- [25] **Kramer, O.** (2013). Dimensionality Reduction with Unsupervised Nearest Neighbors. Germany. Springer-Verlag Berlin Heidelberg.
- [26] **Rokach, L. & Maimon, O.** (2015). Data Mining with Decision Trees Theory and Applications. Singapore. World Scientific Publishing.
- [27] **Zhou, Z. H.** (2012). Ensemble Methods Foundations and Algorithms. UK. Taylor & Francis Group, LLC.
- [28] **Thakur, A.** (2020). Approaching (Almost) Any Machine Learning Problem.
- [29] **Url-3** < <https://forums.ni.com/t5/Ni-Labs-Toolkits/NeuroSky-LabVIEW-Driver/tap/3520085> >, erişim tarihi 13.06.2022.
- [30] **Url-4** < <https://github.com/abdullahbas/IRIS-MRS-AI> >, erişim tarihi 14.06.2022.

ÖZGEÇMİŞ



Ad-Soyad : Kübra İZCİ

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2013, Eskişehir Osmangazi Üniversite, Mühendislik ve Mimarlık Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : 2022, Bursa Teknik Üniversite, Lisansüstü Eğitim Enstitüsü, Akıllı Sistemler Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2015-Halen Ottonom Mühendislik Çözümleri A.Ş. görev almaktadır.

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Kübra İZCİ, Gökay BAYRAK; Dalgacık Dönüşümü Tabanlı Hibrit Makine Öğrenmesi Yöntemiyle İnsansız Kara Aracının Otonom Kontrolü - Uluslararası Teknolojik Bilimler ve Tasarım Sempozyumu (ITESDES-2022), Haziran 2022, Giresun

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

-
-