

**ELEKTROENSEFALOGRAFI İŞARETLERİNİN
MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE
İNCELENMESİ VE SINIFLANDIRILMASI**

Şule BEKİRYAZICI



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTROENSEFALOGRAFI İŞARETLERİNİN MAKİNE ÖĞRENMESİ
ALGORİTMALARI İLE İNCELENMESİ VE SINIFLANDIRILMASI**

Şule BEKİRYAZICI
0000-0001-9002-7896

Prof. Dr. Güneş YILMAZ
(Danışman)

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2020
Her Hakkı Saklıdır

TEZ ONAYI

Şule BEKİR YAZICI tarafından hazırlanan "Elektroensefalografi İşaretlerinin Makine Öğrenmesi Algoritmaları İle İncelenmesi ve Sınıflandırılması" adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Güneş YILMAZ

Başkan : Prof. Dr. Güneş YILMAZ
0000-0001-8972-1952
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Elektronik Mühendisliği Anabilim Dalı

İmza

Üye : Prof. Dr. Erdoğan DİLAVEROĞLU
0000-0002-8432-623X
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Elektronik Mühendisliği Anabilim Dalı

İmza

Üye : Doç. Dr. Cemal HANILÇI
0000-0002-9174-0367
Bursa Teknik Üniversitesi,
Mühendislik ve Doğa Bilimleri Fakültesi,
Elektrik-Elektronik Mühendisliği Anabilim Dalı

İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.....

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

15/06/2020

Şule BEKİRYAZICI

ÖZET

Yüksek Lisans Tezi

ELEKTROENSEFALOGRAFI İŞARETLERİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE İNCELENMESİ VE SINIFLANDIRILMASI

Şule BEKİRYAZICI

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Güneş YILMAZ

Elektroensefalografi (EEG) işaretleri temel alınarak oluşturulan Beyin-Bilgisayar Arayüzü araştırmaları, mevcut çalışmalardan daha yüksek sınıflandırma başarımı ve daha hızlı sistemlerin kurulmasını amaçlamaktadır. Bu tez çalışmasında Beyin-Bilgisayar Arayüzü sistemleri için EEG verilerinin sınıflandırılması işlemi gerçekleştirilmiştir. EEG işaretleri içerisindeki gürültü kaynaklı bozuklukların belirli oranda ortadan kaldırılabilmesi ve işaretlerin bütünü standartlaştırılması amacıyla verilere standart sapma normalizasyonu uygulanmıştır. Ayrıca her bir frekans bandındaki bilginin ayrı ayrı elde edilebilmesi için işaretler alt frekans bandlarına ayrıştırılmıştır. Devamında, işaretlere farklı öznitelik grupları uygulanarak en yüksek sınıflandırma başarısını gösteren öznitelik grubu, çalışmada kullanılmak üzere seçilmiştir. Öznitelik matrisi içerisindeki yetersiz özniteliklerin çıkarılması için Ardışık İleri Yönde Seçim Algoritması kullanılmıştır. Çalışmada sınıflandırıcı performanslarının karşılaştırılması ve en yüksek sınıflandırma başarımının elde edilebilmesi için iki farklı yöntem önerilmiştir. Önerilen ilk yöntemde, makine öğrenmesi tabanlı klasik sınıflandırıcılardan k-En Yakın Komşuluk, Destek Vektör Makineleri ve Doğrusal Ayırım Analizi algoritmaları ile sınıflandırma işlemi gerçekleştirilmiştir. İkinci yöntemde ise derin öğrenme tabanlı sınıflandırıcılardan olan Derin Sinir Ağları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Derin Sinir Ağları ile iki, dört, sekiz ve on altı katmanlı derin ağ modelleri oluşturulmuş ve sınıflandırma başarıları analiz edilmiştir.

Tez çalışması sonucunda, k-En Yakın Komşuluk ile %89,4 Destek Vektör Makineleri ile %88,7 Doğrusal Ayırım Analizi ile %88,3 iki-katmanlı temel sinir ağı modeli ile %88,07 dört-katmanlı derin sinir ağı modeli ile %92,5 sekiz-katmanlı derin sinir ağı modeli ile %96,82 ve on altı-katmanlı derin sinir ağı modeli ile %94,67 sınıflandırma başarısı elde edilmiştir. Elde edilen sonuçlar, EEG tabanlı Beyin-Bilgisayar Arayüzü sistemlerinde derin öğrenme tabanlı sınıflandırıcıların, makine öğrenmesi tabanlı klasik sınıflandırıcılara göre daha yüksek sınıflandırma başarısı verdiği görüşünü desteklemektedir.

Anahtar Kelimeler: Elektroensefalografi, beyin-bilgisayar arayüzü, öznitelik çıkarma, sınıflandırma, makine öğrenmesi, derin öğrenme

2020, viii + 89 sayfa.

ABSTRACT

MSc Thesis

ANALYSIS AND CLASSIFICATION OF ELECTROENCEPHALOGRAPHY SIGNAL USING MACHINE LEARNING ALGORITHMS

Şule BEKİRYAZICI

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Electronic Engineering

Supervisor: Prof. Dr. Güneş YILMAZ

Brain-Computer Interface research, based on electroencephalography (EEG) signals, aims to achieve higher classification performance and faster systems than existing studies. In this thesis study, the classification of EEG data for Brain-Computer Interface systems has been performed. Standard deviation normalization has been applied to the data in order to eliminate the noise-related defects within the EEG signals and to standardize the whole signals. In addition, the signals are divided into lower frequency bands so that the information in each frequency band can be obtained separately. Subsequently, different feature groups were applied to the signals, and the feature groups showing the highest classification success were selected. Sequential Forward Selection Algorithm is used to remove insufficient features within the feature matrix. In the study, two different methods are proposed to compare classifier performances and to achieve the highest classification performance. In the first proposed method, the classification was carried out with k-Nearest Neighborhood, Support Vector and Linear Discriminant Analysis algorithms, which are among the machine learning based classifiers. In the second method, the classification was carried out using Deep Neural Networks, one of the deep learning based classifiers. In Deep Neural Networks, two, four, eight and sixteen layer deep network models were created and classification successes were analyzed.

As a result of the thesis study, a classification success of 89.4% with k-Nearest Neighborhood, 88.7% with Support Vector Machines, 88.3% with Linear Discrimination Analysis, 88.07% with two-layer basic neural network model, 92.5% with four-layer deep neural network model, 96.82% with eight-layer deep neural network model and 94.67% with sixteen-layer deep neural network model. The results obtained support the view that deep learning based classifiers give higher classification success in EEG based Brain-Computer Interface systems than machine learning based classifiers.

Keywords: Electroencephalography, brain-computer interface, feature extraction, classification, machine learning, deep learning

2020, viii + 89 pages.

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması, Bursa Uludağ Üniveristesi Elektronik Mühendisliği Anabilim Dalı, Elektronik Bilim Dalı Yüksek Lisans Programı'nda hazırlanmıştır. Tez çalışmasında Beyin-Bilgisayar Arayüzü Sistemleri için bilgisayar ekranına yansıtılan sembolün sağa ve sola hareket ettirilmesinin hayali sırasında kaydedilen açık kaynaklı bir EEG veri seti kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Tez çalışmam sürecinde bilimsel desteği ve değerli düşünceleri ile bana çalışmamın her aşamasında yardımcı olan danışman hocam Sayın Prof. Dr. Güneş YILMAZ' a saygı ve teşekkürlerimi sunarım. Ayrıca bu zorlu süreçte bilgi birikimini her daim benimle paylaşarak desteğini benden esirgemeyen sevgili eşim Arş. Gör. Tahir BEKİR YAZICI' ya sevgilerimi ve teşekkürlerimi sunarım.

Eğitim ve öğretim hayatımın tamamında benden hiçbir desteğini esirgemeyen sevgili annem Safinaz YAPICI, sevgili babam Turan YAPICI ve canım kardeşim Büşra YAPICI'ya teşekkürü bir borç bilirim.

Bu tez çalışmasının, bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Şule BEKİR YAZICI

15/06/2020

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	viii
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI.....	2
2.1. Kuramsal Temeller.....	2
2.1.1. Sinir hücresi.....	2
2.1.2. Aksiyon potansiyeli.....	3
2.1.3. İnsan beyni.....	5
2.1.4. Elektroensefalografi.....	7
2.1.5. EEG işaretleri ve özellikleri.....	7
2.1.6. Beyin bilgisayar arayüzü sistemleri.....	10
2.2. Elektrot Analizi.....	14
2.2.1. Tersinir ve tersinmez elektrotlar.....	14
2.2.2. Ag-AgCl elektrotlar.....	15
2.2.3. EEG işaretlerinin ölçülmesi.....	16
2.3. Kaynak Araştırması.....	18
2.4. Tezin Kapsamı ve Konusu.....	22
3. MATERYAL ve YÖNTEM.....	23
3.1. Kullanılan Veri Setinin Açıklanması - BCI Competitions II Veri Seti.....	23
3.2. Ön İşleme Yöntemleri.....	25
3.2.1. Normalizasyon.....	25
3.2.2. EEG işaretlerinin alt frekans bandlarına ayrılması.....	25
3.3. Öznitelik Çıkarma Yöntemleri.....	26
3.3.1. Fourier dönüşümü yöntemi.....	27
3.3.2. Dalgacık dönüşümü yöntemi.....	29
3.3.3. Hilbert dönüşümü yöntemi.....	31
3.4. Ardışık İleri Yönde Seçim Algoritması.....	32
3.5. Makine Öğrenmesi Tabanlı Klasik Sınıflandırma Yöntemleri.....	34
3.5.1. k-en yakın komşuluk algoritması.....	34
3.5.2. Destek vektör makineleri algoritması.....	36
3.5.3. Doğrusal ayırım analizi algoritması.....	37
3.5.4. Sınıflandırıcı eğitim yöntemi (k-kat çapraz onaylama).....	38
3.5.5. Sınıflandırma başarımlar ölçütleri.....	39
3.6. Derin Öğrenme Tabanlı Sınıflandırma Yöntemleri.....	41
3.6.1. Sinir ağları ve matematiksel modeli.....	41
3.6.2. Sinir ağlarında ileri ve geri yayılım algoritmaları.....	43
3.6.3. İki-katmanlı temel sinir ağı yapısı.....	44
3.6.4. Aktivasyon fonksiyonları.....	46
3.6.5. Sinir ağlarında hiperparametrelerin tanımlanması.....	49
3.6.6. Derin sinir ağları (deep neural network).....	51
3.7. Önerilen Yöntemin Akış Diyagramı.....	52
4. BULGULAR.....	54

4.1. Ön İşleme Yöntemleri Analizi	54
4.2. Öznitelik Grubu Seçim Analizi	55
4.3. Ardışık İleri Yönde Seçim Algoritması Analizi.....	58
4.4. k-EYK Algoritması Sınıflandırma Başarısı Analizi	59
4.5. DVM Algoritması Sınıflandırma Başarısı Analizi.....	61
4.6. DAA Algoritması Sınıflandırma Başarısı Analizi	63
4.7. Derin Sinir Ağları Algoritması Sınıflandırma Başarısı Analizi.....	64
4.7.1. İki-katmanlı temel sinir ağı modeli sınıflandırma başarısı analizi.....	64
4.7.2. Dört-katmanlı derin sinir ağı modeli sınıflandırma başarısı analizi.....	69
4.7.3. Sekiz-katmanlı derin sinir ağı modeli sınıflandırma başarısı analizi	72
4.7.4. On altı-katmanlı derin sinir ağı modeli sınıflandırma başarısı analizi.....	74
5. TARTIŞMA VE SONUÇ	77
KAYNAKLAR	82
ÖZGEÇMİŞ	89

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
$Ag-AgCl$	Gümüş-Gümüş Klorür
Ca^{2+}	Kalsiyum İyonu
Cl^{-}	Klor İyonu
$d_{minkovski}$	Minkowski Uzaklık Fonksiyonu
$d_{manhattan}$	Manhattan Uzaklık Fonksiyonu
$d_{öklid}$	Öklid Uzaklık Fonksiyonu
Hz	Hertz
J	Kayıp Fonksiyonu
K^{+}	Potasyum İyonu
mv	Milivolt
Na^{+}	Sodyum İyonu
μV	Mikrovolt
δ	Delta Dalgası
θ	Teta Dalgası
α	Alfa Dalgası
β	Beta Dalgası
γ	Gama Dalgası

Kısaltmalar	Açıklama
AIYS	Ardışık İleri Yönde Seçim
BBA	Beyin-Bilgisayar Arayüzü
BFA	Böl ve Fethet
BS	Bayes Sınıflandırıcı
DAA	Doğrusal Ayırım Analizi
DSA	Derin Sinir Ağları
DVM	Destek Vektör Makineleri
ECoG	Elektrokortikografi
EEG	Elektroensefalografi
ESA	Evrişimsel Sinir Ağları
fMRI	Fonksiyonel Manyetik Rezonans Görüntüleme
FN	Yanlış-Negatif Oranı
FP	Yanlış-Pozitif Oranı
k-EYK	k-En Yakın Komşuluk
LFP	Yerel Alan Potansiyelleri
MEG	Manyetoensefalografi
ROKA	Rastgele Orman Karar Ağacı
SNR	Sinyal-Gürültü Oranı
TN	Doğru-Negatif Oranı
TP	Doğru-Pozitif Oranı
TSB	Toplam Sınıflandırma Başarısı
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Sinir hücresi yapısı.....	2
Şekil 2.2. Aksiyon potansiyeli.	3
Şekil 2.3. Frontal ve pariyetal loblar.	5
Şekil 2.4. Temporal ve oksipital loblar.	6
Şekil 2.5. EEG dalga formları ve frekans aralıkları.	8
Şekil 2.6. Ortaya çıkma şekline göre EEG işareti grupları.	9
Şekil 2.7. EEG tabanlı beyin-bilgisayar arayüzü sistemi.....	12
Şekil 2.8. Tersinir ve tersinmez elektrot yapısı.....	15
Şekil 2.9. 10-20 elektrot standart yerleşim sistemi yandan ve tepeden bakış.....	17
Şekil 3.1. Veriseti-I elektrot lokasyonları.	23
Şekil 3.2. Veriseti-I deney prosedürü.....	24
Şekil 3.3. Ardışık ileri seçim algoritması kafes yapısı.....	33
Şekil 3.4. k-EYK Algoritması için örnek.....	34
Şekil 3.5. Doğrusal DVM ve optimum hiperdüzlem yapısı.....	36
Şekil 3.6. K-kat çapraz onaylama yöntemi.	39
Şekil 3.7. İki sınıflı bir problemde hata matrisi.	40
Şekil 3.8. Sinir hücresi matematiksel modeli.....	42
Şekil 3.9. İleri ve geri yönde yayılım algoritması temel yapısı.	43
Şekil 3.10. İki katmanlı sinir ağı yapısı.	44
Şekil 3.11. L-boyutlu derin sinir ağı yapısı	51
Şekil 3.12. Önerilen yöntem-1 akış diyagramı.....	52
Şekil 3.13. Önerilen yöntem-2 akış diyagramı.....	53
Şekil 4.1. Uygulanan tüm öznelikler için en yüksek sınıflandırma doğrulukları.	58
Şekil 4.2. k-EYK algoritması en yüksek sınıflandırma doğruluğu hata matrisi.	61
Şekil 4.3. DVM algoritması en yüksek sınıflandırma doğruluğu hata matrisi.	62
Şekil 4.4. DAA algoritması en yüksek sınıflandırma doğruluğu hata matrisi.	64
Şekil 4.5. 2-katmanlı sinir ağı modeli eğitim başarımı grafiği-1.	67
Şekil 4.6. 2-katmanlı sinir ağı modeli eğitim başarımı grafiği-2.	68
Şekil 4.7. 2-katmanlı sinir ağı modeli eğitim başarımı grafiği-3.	68
Şekil 4.8. 4-katmanlı derin sinir ağı modeli eğitim başarımı grafiği.	71
Şekil 4.9. 8-katmanlı derin sinir ağı modeli ve hiperparametre değerleri.....	72
Şekil 4.10. 8-katmanlı derin sinir ağı modeli eğitim başarımı grafiği.	74
Şekil 4.11. 16-katmanlı derin sinir ağı modeli ve hiperparametre değerleri.....	75
Şekil 4.12. 16-katmanlı derin sinir ağı modeli eğitim başarımı grafiği.	77

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. EEG işaretlerine uygulanan öznitelik grupları.....	26
Çizelge 3.2. Dalgacık fonksiyonları matematiksel ifadeleri	30
Çizelge 3.3. Aktivasyon fonksiyonları.....	47
Çizelge 4.1. Tüm öznitelik grupları için k-EYK algoritması sınıflandırma başarıları....	55
Çizelge 4.2. Tüm öznitelik grupları için DVM algoritması sınıflandırma başarıları.....	56
Çizelge 4.3. Tüm öznitelik grupları için DAA algoritması sınıflandırma başarıları	57
Çizelge 4.4. Öznitelik-9 grubu veri boyutları	58
Çizelge 4.5. k-EYK algoritması sınıflandırma sonuçları	60
Çizelge 4.6. DVM algoritması sınıflandırma sonuçları	62
Çizelge 4.7. DAA algoritması sınıflandırma sonuçları	63
Çizelge 4.8. 2-katmanlı temel sinir ağı modeli sınıflandırma sonuçları	65
Çizelge 4.9. 4-katmanlı derin sinir ağı modeli sınıflandırma sonuçları.....	69
Çizelge 4.10. 8-katmanlı derin sinir ağı modeli detayları.....	73
Çizelge 4.11. 16-katmanlı derin sinir ağı modeli detayları.....	76
Çizelge 5.1. Sınıflandırma Başarıları Analizi	81

1. GİRİŞ

Bilim dünyasında insanların günlük hayatlarının kolaylaşabilmesi ve hayat standartlarının arttırılabilmesi için bir çok yeni teknoloji gelişmeye devam etmektedir. Bu teknolojiler içerisinde Beyin-Bilgisayar Arayüzü (BBA) sistemleri önemli çalışma alanlarından biridir. Zihin-Makine Arayüzü (Mind-Machine Interface) ve Beyin-Makine Arayüzü (Brain-Machine Interface) olarak bilinen BBA sistemleri, motor sinir sistemi öğelerini kullanmak yerine beyin ve makine olarak tanımlanan harici bir cihaz arasında doğrudan iletişim yolunun kurulması olarak tanımlanmaktadır. BBA sistemleri sayesinde, kişi kas sistemlerini devreye sokmadan sadece düşünceleriyle bilgisayar, klavye, robot, tekerlekli sandalye, protez vb. harici cihazları kontrol edilebilmektedir (Muglerab ve ark. 2008, Williamson ve ark. 2009, Krauledat ve ark. 2009, Millán ve ark. 2009).

BBA sistemlerinin en önemli alanlarından biride sağlık uygulamalarıdır. Bu sistemler beyin-omurilik yaralanmalarına, beyin travmalarına, merkezi sinir sisteminde meydana gelen hasarlar sonucu oluşan hastalıklarına, kas hastalıklarına vb. sahip hastaların hayatlarını kolaylaştırabilmeleri açısından önemli bir teknoloji olmaktadır. Bu tarz hastalıklarda, hastanın sadece motor sinir sistemi öğeleri etkilenmekte fakat zihinsel işlevleri zarar görmemektedir (Wolpaw ve ark. 2002).

Günümüzde BBA sistemleri uygulamaları için invaziv olan ve invaziv olmayan ölçüm teknikleri kullanılmaktadır. İnvaziv ölçüm teknikleri kullanılarak oluşturulan BBA sistemlerinde elektrokortikografi (ECoG) ve yerel alan potansiyelleri (LFP) yöntemleri uygulanmaktadır. İnvaziv olmayan ölçüm teknikleri kullanılarak oluşturulan BBA sistemlerinde elektroensefalografi (EEG), fonksiyonel manyetik rezonans görüntüleme (fMRI) ve manyetoensefalografi (MEG) yöntemleri uygulanmaktadır. (Huang ve ark. 2009, Eklund ve ark. 2010, O'Doherty ve ark. 2011, Schalk ve Leuthardt 2011).

Bu teknikler içerisinde EEG işaretleri kolay elde edilebilir, kullanılabilir ve uygulanabilir olması nedeniyle BBA sistemlerinde oldukça yaygın olarak kullanılmaktadır (O'Doherty ve ark. 2011, Schalk ve Leuthardt 2011, Xiao ve Ding 2013).

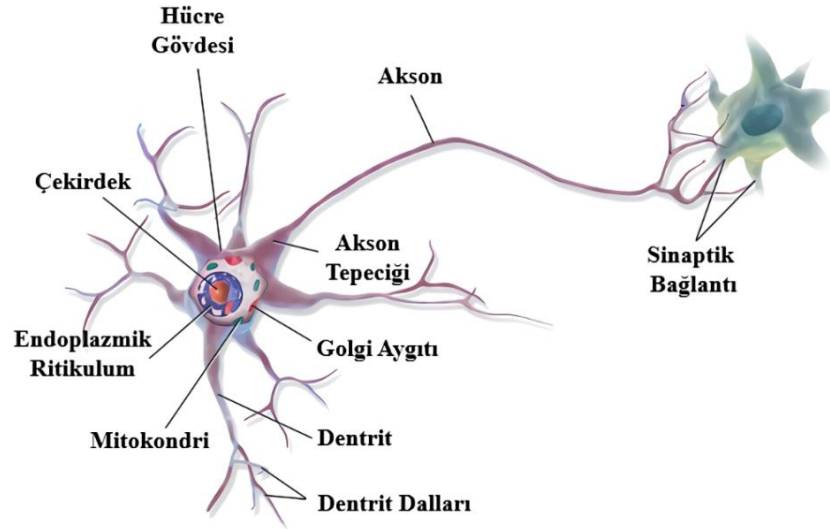
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1. Kuramsal Temeller

Bu bölümde; sinir hücresi, aksiyon potansiyeli, insan beyni, elektroensefalografi, EEG işaretleri ve özellikleri beyin-bilgisayar arayüzü sistemleri ve elektrot analizi gibi temel bilgiler verilmektedir.

2.1.1. Sinir hücresi

Sinir hücresi (nöron), iç ve dış çevreden gelen uyarımların alınması ve iletilmesi ile görevli olan beynin temel görev ve yapı birimidir. Sinir hücreleri dendrit, hücre gövdesi (soma) ve akson olmak üzere üç kısımdan oluşmaktadır. Dendrit, merkezi sinir sisteminden veya diğer sinir hücrelerinden gelen uyarımları hücre gövdesine iletmektedir. Hücre gövdesinin içerisinde hücre çekirdeği ve organeller bulunmaktadır. Bu bileşenler sayesinde dendritlerden gelen bilgi anlamlandırılmaktadır. Akson ise bu bilginin diğer sinir hücrelerine iletilmesi ile görevlidir. Örnek bir nöron yapısı Şekil 2.1’ de verilmektedir.



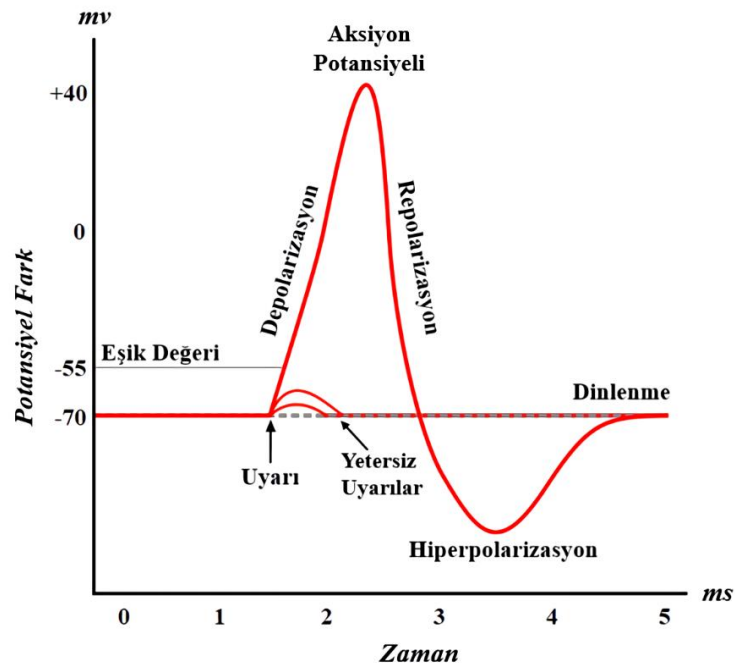
Şekil 2.1. Sinir hücresi yapısı.

Aksonların dış yüzeyinde yağ dokudan oluşan korucu kılıfa miyelin kılıf denir. Bu kılıf akson boyunca uyarımların daha hızlı ilerlemesini sağlamaktadır. Miyelin kılıfı bulunan aksanlarda uyarım hızı ortalama 120 m/s’ dir.

Bir sinir hücresinin akson ucu ile başka bir sinir hücresinin dendritinin ortak bağlantı noktasına sinaps adı verilmektedir. Sinaps bölgelerinde oluşan sinaptik akımlar sayesinde, uyarımlar nöronlar arasında iletilmektedir. Sağlıklı bir insan beyninde yaklaşık 10^{10} adet sinir hücresi ve 10^{14} adet sinaptik birleşme noktası bulunmaktadır.

2.1.2. Aksiyon potansiyeli

Sinir, kas ve bez dokularında bulunan hücrelerde (uyarılabilir hücreler) K^+ , Na^+ , Ca^{2+} ve Cl^- gibi iyonların hareketleri sayesinde elektrokimyasal aktiviteler meydana gelmektedir. Elektrokimyasal aktiviteler, hücre içinde ve dışında potansiyel farkların oluşmasına sebep olmaktadır. Hücre zarında meydana gelen bu potansiyelin ani ve hızlı artıp azalmasından dolayı oluşan voltaj değişimlerine aksiyon potansiyeli adı verilmektedir. Bu potansiyel sinir hücresi boyunca akson uçlarına kadar iletilmektedir. Sinir hücreleri bu sayede oldukça uzun mesafelerde bilgi aktarımı yapabilmektedir. Aksiyon potansiyeli oluşumu Şekil 2.2' de gösterilmektedir.



Şekil 2.2. Aksiyon potansiyeli.

Uyarılabilir hücrelerde, hücre içinde ve dışında bulunan iyonların konsantrasyonları farklıdır. Hücre dışında Na^+ , Ca^{2+} ve Cl^- iyonlarının konsantrasyonları daha fazlayken,

hücre içerisinde K^+ iyonunun konsantrasyonu daha fazladır. Hücre zarında bulunan Na^+ - K^+ pompası adı verilen aktif taşıma kanalları, konsantrasyon farkını sabit tutmak için difüzyon yoluyla hücre içine doğru K^+ , hücre dışına doğru Na^+ iyonlarını taşımaktadır. Bu durumda oluşan potansiyel fark, hücre içinden hücre dışına doğru -70 mV seviyesindedir. Hücrenin içi ve dışı arasında sabit bir potansiyel farkın olduğu bu duruma "dinlenme durumu" adı verilmektedir.

Sinir hücrelerine eşik seviyesinin (-55 mV) üzerinde bir uyarım geldiğinde Na^+ iyonları hücre dışından hücre içine doğru difüzyon yoluyla hareket etmektedir. Bu durumda hücre içi, hücrenin dışına göre pozitif hale gelmektedir. Bu olaya "depolarizasyon" adı verilmektedir. Depolarize durumdaki bir hücrenin potansiyeli +35 mV ile +40 mV aralığındadır.

Depolarizasyon işleminden sonra hücre içerisinde bulunan Na^+ iyonları belli bir konsantrasyon seviyesine ulaştığında, hücre zarında K^+ kanalları açılmakta ve hücre içine Na^+ girişi durdurulmaktadır. Böylece hücrenin iç kısmında derişimi fazla olan K^+ iyonları hücrenin dışına çıkmaya başlamaktadır. Hücre içine giren Na^+ iyonu miktarı kadar K^+ iyonu hücre dışına çıkarak, potansiyel fark dinlenme seviyesine tekrar gelmektedir. Bu olaya "repolarizasyon" adı verilmektedir.

Repolarizasyon işlemi sonrası, açılan K^+ kanalları daha yavaş kapandığından hücrenin dışına daha fazla K^+ iyonu çıkışı olmaktadır. Bu sebeple hücre içi potansiyel dinlenme durumu seviyesine (-70 mV) dönmek isterken -85 mV değerine kadar düşebilmektedir. Bu durum "hiperpolarizasyon" olarak adlandırılmaktadır.


Potansiyel farkın dinlenme seviyesi ulaşması sonrasında, hücre içerisinde Na^+ hücre dışına ise K^+ iyonu derişimi daha fazladır. Sinir hücrelerinin dinlenme durumuna yeniden ulaşabilmesi için Na^+ ve K^+ iyonlarının yer deęiştirilmesi gerekmektedir. Bu işlem Na^+ - K^+ pompası tarafından ATP harcanarak gerçekleştirilir. Bu sayede hücre yeniden dinlenme durumuna getirilmektedir.

2.1.3. İnsan beyni


Milyonlarca sinir hücresinden oluşan beyin, hala çözülememiş kısımları bulunan karmaşık bir yapıya sahiptir. İnsan beyninin, omurilik ve sinirler vasıtasıyla merkezi sinir sisteminin kontrol edilmesi, çevresel sinir sisteminin yönetilmesi ve günlük hayatta yapılan tüm işlevlerin düzenlenmesi gibi önemli görevleri bulunmaktadır. Bunlarla birlikte kalp atışı, sindirim, soluk alma gibi istemsiz eylemleri ve düşünce, mantık, soyutlama gibi karmaşık zihinsel eylemlerin yönetimi beyin tarafından gerçekleştirilmektedir.

İnsan beyni gri ve beyaz madde olmak üzere iki farklı maddeden meydana gelmektedir. Sinir hücrelerinin aksonları beyaz maddeyi oluşturmaktadır. Beyin içerisindeki görevi, hücreler arası bağlantının kurulması olarak tanımlanmaktadır. Gri madde, beyin (serebrum) ve beyinciğin (serebellum) dış kısımlarını örten beyin zarıdır. Kalınlığı 1,5 mm-5 mm arasında değişmektedir. Gri maddenin serebrumu örten bölümüne “serebral korteks” adı verilmektedir. Beyin ve onu koruyan tabakalar içeriden dışa doğru beyaz madde, serebral korteks, kafatası ve deri olarak sıralanmaktadır.

Serebral korteks, insan beyninin en gelişmiş kısmıdır. Ağırlıklı bakımından beyin 2/3'ünü teşkil etmekte ve beyin neredeyse tüm yapılarının üstünü örtmektedir. Serebral korteks, yapısal olarak dört ana lobdan oluşmaktadır. Bunlar; frontal lob, pariyetal lob, temporal lob ve oksipital lob olarak sıralanmaktadır. Belirtilen bu loblar Şekil 2.3 ve Şekil 2.4'te verilmektedir.



Şekil 2.3. Frontal ve pariyetal loblar.



Şekil 2.4. Temporal ve oksipital loblar.

Frontal lob, serebral loblar içerisindeki en büyük lobdur. Beynin ön kısmında bulunmaktadır. Motor işlevleri, yüksek mertebeli beyin işlemleri, planlama, muhakeme, karar verme, dürtü kontrolü, hafıza gibi yoğun zihinsel işlemlerin gerçekleştiği bölümdür. Pariyetal lob, frontal lobun arka kısmında ve temporal lobun üst kısmında bulunmaktadır. Algılama, bilgi işlenmesi, şekil ayrımı, renk ayrımı, dokunma hissi, konuşma, mekansal yön belirleme, aritmetik yetenekler ve görsel algılama gibi duyuşal işlemlerin gerçekleştirildiği bölümdür.

Temporal lob, frontal ve pariyetal lobların alt kısmında yer almaktadır. Temporal lob, başın her iki tarafında bulunmaktadır. Kulakların üst kısmında yer almasından dolayı en önemli görevi işitsel bilgileri işlemesidir. Aynı zamanda uzun süreli bellek, işitsel öğrenme, kelimeleri yeniden düzenleme, müzik farkındalığı ve dili anlama işlemlerinde gerçekleştirildiği bölümdür.

Oksipital lob, pariyetal lobun arkasında yer almaktadır. En önemli işlevi göz duyusundan gelen görsel bilgileri işlemesidir. Oksipital loblarda meydana gelebilecek hasarlar, görsel halüsinasyonlara ve görsel ilüzyonlara yol açabilmektedir.

Serebral korteksin bölümlerinden biri motor korteksdir. Motor korteks, beynin motor işlevlerinden sorumlu bölümüdür. Frontal lobda bulunmaktadır. Duyuşal kortekst tarafından gönderilen bilgiler doğrultusunda vücut hareketlerinin planlanması, denetlenmesi ve uygulanması işlemlerinden sorumludur.

2.1.4. Elektroensefalografi


İnsan beyninde bulunan milyonlarca sinir hücresinin elektriksel yük ve iyon hareketleri sonucunda, kafatası yüzeyinde elektrik akımları oluşmaktadır. Elektroensefalografi (EEG), kafatası üzerindeki bu elektriksel akımların, Ag-AgCl elektrotlar yardımıyla izlenmesine ve kaydedilmesine olanak sağlayan ölçüm tekniği olarak tanımlanmaktadır. Elektroensefalografi; elektro (elektriksel), ensefalo (beyin), gram (kayıt) kelimelerinin birleşmesi ile oluşmaktadır. (Teplan 2002).

Elektroensefalografinin tarihsel gelişimi, 1875 yılında Richard Caton'un hayvanlar üzerinde yaptığı deneyler sonucu beyindeki elektriksel aktiviteyi keşfetmesi ile başlamıştır. İnsan beynindeki elektriksel aktivitenin varlığı ise 1929 yılında Alman psikiyatrist Hans Berger'in yaptığı deneyler ile ortaya çıkmıştır. Berger, kafatası üzerine yerleştirdiği elektrotları bir galvanometreye bağlayarak insan beyin aktivitesini keşfetmiştir. Bu gelişme, bilim dünyasında büyük bir buluş olmuştur. Aynı zamanda Berger, 1930 yılında EEG dalgalarının göz hareketleri ile değiştiğini gözlemlemiştir. Berger'dan sonra, 1934 yılında Brian Matthews ve Edgar Douglas Adrian, EEG işaretlerinin kuvvetlendirilmesine ve kaydedilmesine olanak sağlayacak bir çalışma gerçekleştirmişlerdir (Niedemeyer ve Da Silva 2005). Teknolojideki gelişmeler ile birlikte sonraki yıllarda, bu alanda yapılan çalışmalar artmış ve elektriksel aktivitesinin ölçülmesiyle insan beyninin yapısı açıklanmaya çalışılmıştır (Malmivuo ve ark. 1995).

2.1.5. EEG işaretleri ve özellikleri

Elektroensefalografi ölçüm tekniği kullanılarak kaydedilen sinyallere EEG işaretleri denmektedir. EEG işaretlerinin genlikleri beyin yüzeyinde tepeden tepeye 1-5 mV, kafa derisi yüzeyinde 1-400 μ V olarak ölçülmektedir. Frekans değeri ise 0.5-100 Hz aralığında değişim göstermektedir. EEG işaretleri periyodik işaretler değildir, genlik, frekans ve faz değerleri sürekli olarak değişmektedir. Sağlıklı insanlarda, bu işaretlerin genlik ve frekansı uyku hali, düşünme hali, uykunun farklı evreleri, zihinsel aktivite vb. durumlarda farklılık göstermektedir (Webster 2009).

EEG işaretleri 0.5-100 Hz arasında değişim göstermiş olsa da, içerisinde fizyolojik bilgi yoğunlukla 0.5 ile 50 Hz arasında bulunmaktadır. Bu frekans aralığında EEG işaretleri beş banda ayrılmaktadır. Bunlar, alçak frekans değerinden yüksek frekans değerine doğru sırasıyla; delta (δ), teta(θ), alfa (α), beta (β), ve gama (γ) dalgalarıdır. Temel EEG dalga formları ve frekans aralıkları Şekil 2.5’ te gösterilmektedir.



Şekil 2.5. EEG dalga formları ve frekans aralıkları.

Delta (δ) Dalgaları: Genlikleri 20-400 μ V ve frekansları 0.5-4 Hz arasında değişen dalga formudur. Derin uyku hali, uyanmaya başlama, genel anestezi gibi beyin aktivitesinin düşük olduğu durumlarda ortaya çıkmaktadır (Sanei ve Chambers 2013).

Teta (θ) Dalgaları: Genlikleri 5-100 μ V ve frekansları 4-8 Hz arasında değişen dalga formudur. Çocuklarda temporal ve pariyetal loblarda görülmektedir. Sağlıklı yetişkenlerde ise, açık bilincin dinlenme hali, derin meditasyon, stres, rüya görme hali gibi durumlarda ortaya çıkmaktadır (Donchin ve ark. 2000).


Alfa (α) Dalgaları: Genlikleri 2-10 μ V ve frekansları 8-13 Hz arasında değişen dalga formudur. Dalga şekilleri genellikle sinüzoidaldır. Çoğunlukla oksipital lob üzerinden ölçümleri alınmaktadır. Bu bölgeden alınan alfa dalgalarının genlikleri 50 μ V seviyesine

kadar yükselmektedir. Düşünel motor hareketleri ile ilişkilendirilmektedir. Uyanık bireylerde, zihinsel ve fiziksel tam dinlenme durumunda ortaya çıkmaktadır. Ayrıca gözlerin kapatılması halinde de bu dalga formları gözlemlenmektedir (Spyrou ve ark. 2007).

Beta (β) Dalgaları: Genlikleri 1-5 μ V ve frekansları 13-30 Hz arasında değişen dalga formudur. Çoğunlukla pariyetral ve frontal loblar üzerinden ölçümleri alınmaktadır. Merkezi sinir sisteminin yoğun faaliyet gösterdiği durumlarda ve dikkat seviyesinin arttığı konsantrasyon anlarında ortaya çıkmaktadır (Niedermeyer ve Da Silva 2005).

Gama (γ) Dalgaları: Frekans aralığı ortalama 30-50 Hz olarak tanımlanmaktadır. Frontal lob üzerinden ölçümleri alınmaktadır. Genlikleri oldukça düşüktür (Spyrou ve ark. 2007).

EEG işaretleri ortaya çıkma şekline göre iki gruba ayrılmaktadır. Bunlar; faz kilitli olay ilişkili potansiyeller ve olay bağlantılı desenkronizasyon/senkronizasyon (faz kilitli olmayan reaktivite) olarak sıralanmaktadır (Pfurtscheller 1999). Şekil 2.6' da bu gruplar gösterilmektedir.



Şekil 2.6. Ortaya çıkma şekline göre EEG işareti grupları.

Olay ilişkili potansiyeller; belirli bir olay karşısında beyinde ortaya çıkan küçük elektriksel voltajlar olarak tanımlanmaktadır (Blackwood ve Muir 1990). Olay ilişkili potansiyeller; yavaş kortikal potansiyelleri, P300 dalgaları, durağan hal görsel uyarılmış potansiyel ve hata-bağlantı potansiyeli olmak üzere dörde ayrılmaktadır.

Yavaş kortikal potansiyeller (Slow Cortical Potential, SCP); EEG işaretlerinde meydana gelen potansiyel kaymalardır. Hem pozitif hem de negatif yönde gerçekleşmektedir. Potansiyel kaymalar 0.5-10 sn süre aralığında gerçekleşmektedir (Birbaumer 1990).

P300 Dalgaları; zihinsel bir görev gerçekleştirilirken, uyarım geldikten 300 ms sonra ortaya çıkan EEG işaretleridir (Donchin ve ark. 2000). Bu dalgalar beyin-bilgisayar arayüzü uygulamalarında sıklıkla kullanılmaktadır.

Durağan hal görsel uyarılmış potansiyel (Steady-State Visually Evoked Potential, SSVEP); belirlenen sıklıkla tekrar eden görsel uyarım deneylerinde ortaya çıkan potansiyellerdir. Bu potansiyel, beynin optikal korteksinde meydana gelmektedir (Birbaumer ve ark. 1990). Hata-bağlantı potansiyeller (Error-Related Potentials, ErRP); görsel hataların fark edilmesi sonucunda ortaya çıkan potansiyellerdir.

Olay bağlantılı desenkronizasyon/senkronizasyon; bilişsel, duyuşsal ve motor aktiviteler sonucu EEG işaretlerinin olayla ilişki genlik seviyelerinin değişmesi durumudur.

2.1.6. Beyin bilgisayar arayüzü sistemleri

Beyin-bilgisayar etkileşimi teknolojisi son yıllarda bilim insanlarının ve araştırmacıların sıklıkla çalışmalar yaptığı önemli bir alandır. Beyin-bilgisayar etkileşimi teknolojileri içerisinde en çok kullanılanı beyin-bilgisayar arayüz (BBA) sistemleridir (Wolpaw ve ark. 2002, Schwartz ve ark. 2006, Birbaumer 2006).

Fizyolojik işaretleri kullanılarak oluşturulan BBA sistemleri, motor sinir sistemlerini kullanmadan bilgi taşıyan işaret ile bilgisayar arasında doğrudan bir bağlantı kurarak, bilgisayar veya çeşitli nöroprotezler gibi elektronik sistemlerin kontrol edilebilmesine olanak sağlamaktadır (Wang ve ark. 2007).

BBA terimi ilk olarak 1973 yılında Jacques J. Vidal'in yapmış olduğu bir sistem sonucu ortaya çıkmıştır. Vidal yapmış olduğu çalışmada, EEG sinyallerini tanımlayan,

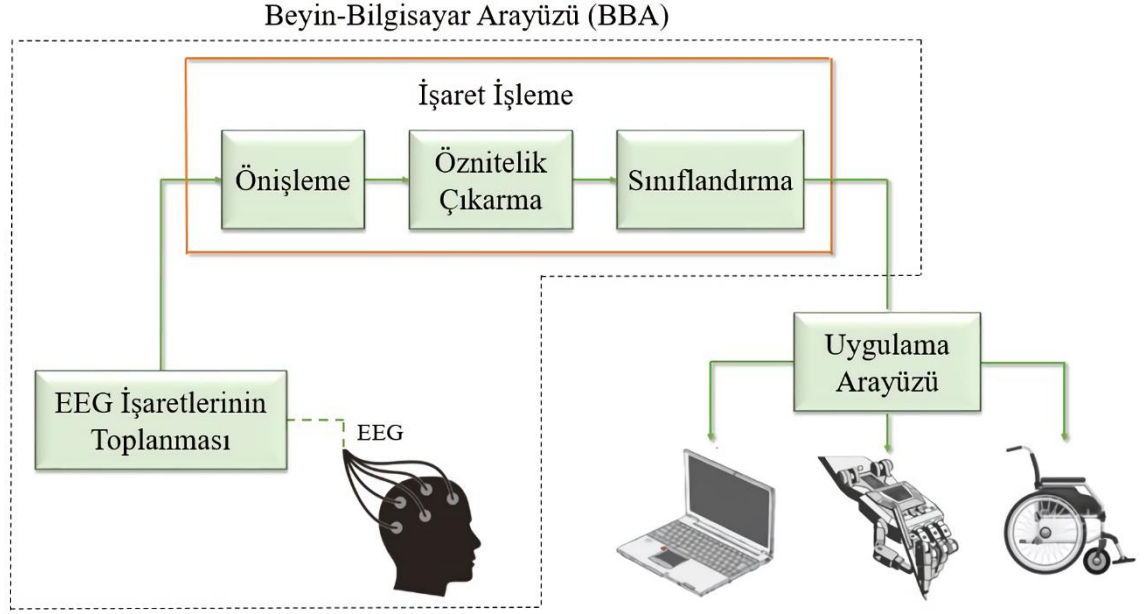
çözümleyen, aralarındaki korelasyon ilişkisini tespit eden ve bulgularını yorumlayan bir sistem geliştirmiştir (Weiskopf ve ark. 2004).

Günümüzde BBA sistemleri uygulamaları için invaziv olan ve invaziv olmayan ölçüm teknikleri kullanılmaktadır. İnvaziv ölçüm teknikleri kullanılarak oluşturulan BBA sistemlerinde elektrokortikografi (ECoG) ve yerel alan potansiyelleri (LFP) yöntemleri uygulanmaktadır. ECoG tekniğinde, beynin selebral korteksi üzerinden alınan EEG ölçümleri, LFP tekniğinde, sinir dokusu içerisindeki birbirine komşu olan nöronlardan akan elektrik akımının oluşturduğu toplam potansiyeller kullanılmaktadır.

İnvaziv olmayan ölçüm teknikleri kullanılarak oluşturulan BBA sistemlerinde elektroensefalografi (EEG), fonksiyonel manyetik rezonans görüntüleme (fMRI) ve manyetoensefalografi (MEG) yöntemleri uygulanmaktadır. MEG tekniğinde, beyin içerisinde oluşan aktivasyonlar sonucu ortaya çıkan elektrik akımının oluşturduğu manyetik alan ile beynin haritası çıkarılmaktadır (Huang ve ark. 2009, Eklund ve ark. 2010, O'Doherty ve ark. 2011, Schalk ve Leuthardt 2011, Zhang ve ark. 2013).

İnvaziv ölçüm tekniklerinde, yüksek işaret gürültü oranı (SNR) ile işaretler toplanmaktadır. Bu teknikler kullanılarak oluşturulan BBA sistemlerinde, yüksek kaliteli işaretler sisteme aktarılmaktadır. Fakat invaziv ölçüm tekniklerinde, işaretlerin toplanması için kullanılan elektrotlar cerrahi işlemler ile vücut içerisine yerleştirilmektedir. Bu da invaziv yöntemleri uygulanması zor bir hale getirmektedir (Georgopoulos ve ark. 2005).

İnvaziv olmayan yöntemler ise kabul edilebilir bir işaret gürültü oranına sahiptir. İşaretlerin elde edilmesi için kullanılan elektrotlar, cerrahi işleme ihtiyaç duymadan yerleştirilebilmektedir. Bu nedenle BBA uygulamalarında invaziv olmayan yöntemler sıklıkla tercih edilmektedir. İnvaziv olmayan yöntemler içerisinde bulunan EEG ölçüm tekniği, kolay elde edilebilir, kullanılabilir ve uygulanabilir olması nedeniyle BBA sistemlerinde sıklıkla kullanılmaktadır (Xiao ve Ding 2013). EEG tabanlı beyin-bilgisayar arayüzü sistemlerinin temel bileşenleri Şekil 2.7' de verilmektedir.



Şekil 2.7. EEG tabanlı beyin-bilgisayar arayüzü sistemi.

Şekil 2.7’ de görüldüğü gibi BBA sistemlerine ait temel işlem adımları; işaretlerin toplanması, önişleme, öznitelik çıkarma ve sınıflandırma olarak sıralanmaktadır.

EEG İşaretlerinin Toplanması: Kafa derisi üzerine yerleştirilen elektrotlar yardımıyla, ham EEG sinyalleri kaydedilmektedir. EEG sinyallerinin genlik seviyelerinin düşük olması sebebiyle, bu işaretler bir ön kuvvetlendirme aşamasından geçirilmektedir. Kuvvetlendirilmiş sinyallerden istenen frekans aralıklarının elde edilmesi amacıyla band geçiren filtre kullanılmaktadır.

Filtreden geçen zayıf sinyallerin tekrardan kuvvetlendirilmesi için kazanç kuvvetlendiricisi ile sistem tamamlanmaktadır. EEG işaretlerinin toplandığı sistemlerde, güç kaynaklarından veya ölçüm cihazlarından oluşabilecek kaçakların neden olabileceği elektrik çarpmalarından korunmak için devre tasarımında izolasyon işlemine önem verilmektedir (Da Silva 2009).

Önişleme: EEG işaretleri, yapısı gereği küçük genlik seviyelerine sahip oldukları için fiziksel ve çevresel gürültü kaynaklarından kolaylıkla etkilenebilmektedir. EEG işaretlerinin toplanması aşamasında, kişinin hareket etmesi, göz kırpması, soluk alıp vermesi gibi kas hareketleri bozucu etki olarak sinyallere eklenmektedir. Tüm bu fiziksel

ya da çevresel gürültü kaynaklarının bozucu etkisinin sinyaller üzerinden kaldırılabilmesi için ön işleme işlemleri gerçekleştirilmektedir.

Öznitelik Çıkarma: EEG işaretleri içerisinde var olan bilgiyi en iyi şekilde ifade edebilecek özelliklerin çıkarılarak öznitelik matrisinin elde edilmesi işlemidir. Öznitelik çıkarma işlemi BBA sistemlerinde en önemli ve en kritik adımlardan biridir. Bu işlem adımında farklı sınıflara ait verilerin, birbirinden en iyi şekilde ayırt edilebilmesine yardımcı olacak özelliklerin çıkarılması gerekmektedir. Çıkarılan özniteliklerin başarısı doğrudan sınıflandırma performansını ve sistemin toplam başarı yüzdesini etkilemektedir.

Literatürde yapılan bir çok çalışmada, farklı sınıfları birbirinden ayırt edebilecek tek öznitelik kullanmak yerine bir çok öznitelik grubunun birlikte kullanılması tercih edilmektedir (Yapıcı ve ark. 2018). Çıkarılan her bir öznitelik, işareti tanımlayabilir fakat sınıflandırma işleminde %100 doğruluk verememektedir. Bu nedenle sisteme ait sınıflandırma başarısının artırılabilmesi için farklı özniteliklerin bir arada kullanılması gerekmektedir.

EEG tabanlı BBA sistemlerinde sinyallerin; varyansı, standart sapması, maksimum değeri, minimum değeri, ortalaması, basıklık katsayısı (kurtosis), çarpıklık katsayısı (skewness), hjorth parametreleri (activity, mobility, complexity), fourier dönüşümü katsayıları, dalgacık dönüşümü katsayıları, ortalama türev değeri, hilbert dönüşümü katsayıları vb. özellikleri literatürde sıklıkla kullanılmaktadır (Wang ve ark. 2007, Mohammed ve ark. 2014, Pattnaik ve ark. 2016).

Sınıflandırma: EEG işaretlerinden çıkarılan özniteliklerin değerlendirilmesi sonucu ilgili işaretin önceden belirlenen bir sınıfa atanması işlemidir. Sınıflandırma işleminde ilk olarak, her bir eğitim verisinden belirli özellikler çıkarılarak öznitelik matrisi oluşturulmaktadır. Devamında öznitelik matrisi ve ilgili sinyallerin etiketleri kullanılarak sınıflandırıcı eğitilmektedir. Test aşamasında ise, test verilerinden çıkarılan öznitelik matrisi eğitilen sınıflandırıcı algoritmasına sokularak, denemenin hangi sınıfa ait olduğuna karar verilmektedir (Mohammed ve ark. 2014, Cheong ve ark. 2015).

2.2. Elektrot Analizi

İnsan vücudundaki biyoelektriksel potansiyellerin ölçülebilmesi için iyonik potansiyel ve akımların elektrik potansiyel ve akımlarına dönüştüren dönüştürücü birimlerine ihtiyaç duyulmaktadır. Tıbbi teşhis amacıyla biyoelektriksel işaretlerin algılanması için insan vücudu ve ölçme düzeneği arasındaki bağlantıyı sağlayan elektronik birimler elektrot olarak adlandırılmaktadır. Elektrotlar, biyolojik işaretlerin algılanması amacının yanı sıra bazı uygulamalarda tedavi amaçlı vücudun belirli bölgelerine akım gönderilmesi için de kullanılmaktadır.


2.2.1. Tersinir ve tersinmez elektrotlar

Elektrotların, insan vücudundaki biyoelektriksel işaretleri algılaması veya dışarıdan uyarım yapmak amacıyla kullanılması, elektron akımının iyon akımına ya da iyon akımının elektron akımına dönüştürülmesi esasına dayanmaktadır. İyon akımının elektron akımına dönüştürme işlemi, elektrotların içerisinde bulunduğu elektrolit ortamında ve elektrot arayüzü arasında gerçekleşmektedir. Elektrot arayüzünde akım taşıyıcı olarak elektronlar bulunmaktadır. Elektrolit tarafında ise akım taşıyıcıları anyonlar ve katyonlar oluşturmaktadır.

Elektrot atomlarının elektronlarını kaybederek elektrolit çözeltisi içerisindeki katyon durumuna gelmesi ve elektrolit çözeltisi içerisindeki katyonların, elektrottan elektron alması sonucu yüzünde birikmesi işlemleri ile iyon-elektron dönüşümü gerçekleşmektedir. Elektrottan akım geçmediği sürece, kimyasal reaksiyon durumunda olan bu işlemler birbirini dengelemektedir.

Tanımlanan denge durumunda, elektrot-elektrolit arayüzünde pozitif yüklü katyon iyonları ile elektrodun arayüze yakın bölgesinde elektronlar birikmektedir. Arayüz üzerindeki yük birikimi, elektrotu çevreleyen elektrolit bölgesinin elektriksel potansiyelinde bir değişiklik meydana getirmektedir. Kullanılan elektrotun yapıldığı malzemeye ve kullanılan elektrolitteki iyon aktivitesine göre değişiklik gösteren bu potansiyel fark yarı-hücre potansiyeli olarak adlandırılmaktadır.

Elektrotlar teorikte polarize olan ve polarize olmayan elektrotlar olmak üzere iki ana bölüme ayrılmaktadır. Polarize olan elektrotlar, elektrot-elektrolit arayüzünde akım geçişi sınırlı olan elektrotlar olarak tanımlanmaktadır. Tamamıyla polarize olan elektrotlardan akım geçmesi durumunda, elektrot elektroliz bölgesinde gerçek bir şarj transferi olmamaktadır. Bu şekilde tamamen polarize olan elektrotlar tersinmez elektrot olarak adlandırılmaktadır. Tersinmez bir elektrot sisteminden hissedilir bir miktarda akım geçirilebilmesi için büyük potansiyel farklara ihtiyaç duyulmaktadır. Şekil 2.8’ de tersinir ve tersinmez elektrot yapıları verilmektedir.



Şekil 2.8. Tersinir ve tersinmez elektrot yapıları.

Birçok uygulamada, çözelti içerisinde iyonu bulunan bir metalin elektrot olarak kullanılması tercih edilmektedir. Arayüzde, herhangi bir potansiyel azalma olmadan akımın iki yönlü hareket edebildiği elektrotlar tersinir elektrotlar olarak adlandırılmaktadır. Tersinir elektrotlarda, elektrot-elektrolit bölgesinden akım serbestçe geçebilmekte ve bu geçiş sırasında bir enerji gereksinimi olmamaktadır.

Şekil 2.8’ de tersinir elektrot yapısında EEG işaretlerinin ölçümünde sıklıkla kullanılan Ag-AgCl (gümüş-gümüşklorür) elektrot yapısı örnek verilmiştir (Tallgren ve ark. 2005).

2.2.2. Ag-AgCl elektrotlar

Ag-AgCl elektrotlar, katı Ag yüzeyinin ince bir katı Ag-AgCl tabakayla kaplanması ya da to şeklindeki AgCl’ nin katı palet şeklinde sıkıştırılması ile oluşmaktadır. Gümüş elektrotun AgCl ile kaplanması sonucunda daha gürültüsüz işaret ölçümleri yapılabilmektedir.

Ag-AgCl elektrotlar ıslak (jelli) ve kuru (jelsiz) olarak kullanılabilir. Islak olarak kullanılan elektrotlarda, deri ile elektrot yüzeyi arasında bir jel sürülerek yüzey empedansı azaltılmaktadır. Bu sayede EEG işaretlerinin zayıflaması engellenmektedir. EEG işaretlerinin ölçülmesinde elektrot ile deri arasındaki kontak empedansı gerilim bölücü etkisi yaratacağı için işaretin elektrot ile algılanmasının ardından bir sonraki kata geçişinde (filtre katı veya kuvvetlendirici katı) bozulmadan ve zayıflamadan geçişi için oldukça önemli bir parametredir. Literatürde yapılan birçok çalışmada, elektrot-deri kontak empedansının 5 k Ω ' dan daha düşük olması gerektiği belirtilmektedir (Casson ve ark. 2010). Günümüzde elektrot-deri kontak empedansı probleminin çözümü için giriş direnci çok yüksek olan biyoelektrik kuvvetlendirici devreleri üretilmiştir. Bu devreler sayesinde elektrot-deri kontak empedansının önemide azalmıştır.

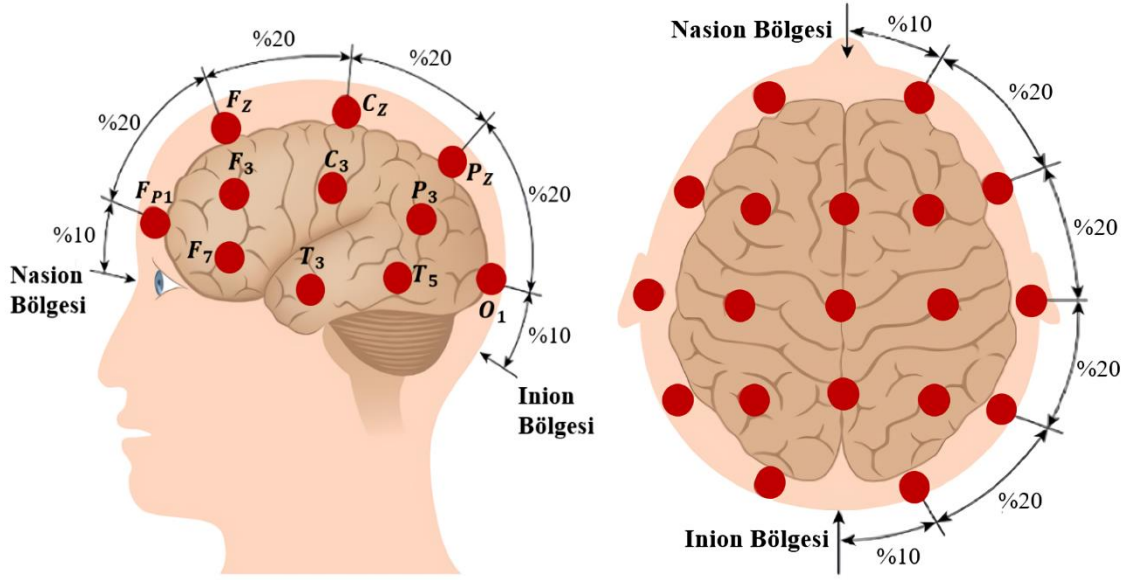
2.2.3. EEG işaretlerinin ölçülmesi

EEG işaretleri küçük genlik seviyelerine sahip işaretlerdir. Bu işaretlerin ölçülmesi esnasında sisteme karışık her türlü bozucu etki (şebeke gürültüsü, harmonikler, ölçüm sisteminde oluşan elektriksel gürültüler, biyolojik işaret kaynakları, EOG, EKG vb.), işaret içerisindeki bilginin kolaylıkla kaybolmasına neden olmaktadır. İşaretin dalga formunun bozulmadan ölçümlerin gerçekleştirilebilmesi için ölçüm sisteminin tasarımı oldukça önemlidir (Malmivuo 1995).

EEG işaretlerinin ölçümlerinde kullanılan elektrotların kafa derisine yerleştirilebilmesi için belirli standartlar bulunmaktadır. Bu standartlardan en çok kullanılan Uluslararası Elektroensefalografi Federasyonu Birliği (International Federation of EEG Societies) tarafından belirlenmiş olan 10-20 elektrot ölçüm sistemidir.

Bu sistemde baş dört ana bölgeye ayrılmaktadır. Bunlar; nasion bölgesi (göz hizası üstü), inion bölgesi (kafa arkası), sağ preauriküler ve sol preauriküler olarak sıralanmaktadır. Elektrotlar, nasion bölgesi ve bölgesi arasında %10-%20-%20-%20-%20-%10 mesafede aralıklar ile kafa derisine yerleştirilmektedir. Kalan elektrotlar, yerleştirilen elektrotlar ile bir daire oluşturacak şekilde sağ ve sol preauriküler bölgelere yerleştirilmektedir. On dokuz elektrot kafa derisine, bir elektrot ise kulak memesine (toprak elektrotu) yerleştirilerek, toplamda yirmi elektrot ise standart ölçümler yapılmaktadır (Malmivuo ve

ark. 1995). Elektrot sayısının artmasının gerektiği durumlarda, 10-10 ya da 10-5 ölçüm sistemlerini kullanılmaktadır (Oostenveld ve Praamstra 2001). Şekil 2.9’ da 10-20 elektrot standartına ait elektrot lokasyonları gösterilmektedir.



Şekil 2.9. 10-20 elektrot standart yerleşim sistemi yandan ve tepeden bakış.

Elektrotlar, yerleştirildikleri yerlerde bulunan lobların isimlerinin baş harfleri kullanılarak etiketlenmektedir. Frontal lob üzerine yerleştirilen elektrotlar F, merkezi sulkus üzerine yerleştirilen elektrotlar C, temporal lob üzerine yerleştirilen elektrotlar T, pariyetal lob üzerine yerleştirilen elektrotlar P ve oksipital lob üzerine yerleştirilen elektrotlar O harfleri kullanılarak adlandırılmaktadır (Webster 2014).

Beynin sol yarım küresine yerleştirilen elektrotlar ilk harflerinin yanına 1, 3, 5, 7 tek sayılarını almaktadır. Beynin sağ yarım küresine yerleştirilen elektrotlar ilk harflerinin yanına 2, 4, 6, 8 çift sayılarını almaktadır. İki yarım küre arasında kalan elektrotlar, ilk harfinin yanına İngilizcede ‘zero’ kelimesinin baş harfi olan ‘z’ harfini almaktadır. Kulak memesi (referans noktası) elektrotları ise A harfi ile etiketlenmektedir (Teplan, 2002).

2.3. Kaynak Araştırması

BBA arařtırmaları ilk olarak 1973 yılında Jacques J. Vidal tarafından gerekleřtirilmiřtir (Vidal 1973). Vidal'den sonra bu alanda yapılan alıřmalar devam etmiř olsa da, bu teknoloji 1999 yılında yapılan, kortikal nronlar ile robotik bir kolun kontrol edilebildiđini gsteren ilk deneysel alıřma sonucunda nemli bir yol kat etmiřtir (Chapin ve ark. 1999). Bu alıřmadan sonra zellikle son 20 yılda BBA uygulamalarına olan ilgi giderek artmıřtır (Lebedev ve Nicolelis 2006).

EEG tabanlı BBA alıřmalarında arařtırmacılar genel olarak, mevcut sistemlerden daha yksek sınıflandırma bařarisına ve daha yksek veri iřleme hızına sahip yeni sistemlerin geliřtirilmesini amalamaktadır. Yksek veri iřleme hızına sahip BBA'ların kurulabilmesi iin znelik ıkarma iřleminde, zelliklerinin sayısının az olaması ve bu zelliklerin sinyali ok iyi řekilde temsil edebilmesi gerekmektedir. Literatrde yapılan alıřmalarda etkin znelikler olarak sıklıkla; fourier ve dalgacık dnřümü tabanlı frekans domeni analizleri (Bhattacharyya ve ark. 2016, Sharma ve ark. 2017, Alickovic ve ark. 2018), P300 ve yavař kortikal potansiyelleri dalga formları (Hou ve ark. 2018, Ditthapron ve ark. 2019), yaklařık entropi (approximate entropy)-rnek entropi (sample entropy)-bulanık entropi (fuzzy entropy) gibi farklı entropi eřitleri (Patidar ve Panigrahi 2017, Arunkumar ve ark. 2018), g spektral yođunluđu (Rajaguru ve Prabhakar 2017, Al Ghayab ve ark. 2018) vb. yntemleri kullanılmaktadır. Ayrıca EEG sinyallerinin farklı frekans blgelerine (delta, teta, alfa, beta, gama dalgaları) ayrı ayrı znelikler uygulanarak, blgeler arası farklılıklar tespit edilebilir ve frekans domeni analizleri glendirilebilmektedir (Trk ve ark. 2017, Onay ve Kse 2019).

Literatrde yapılan alıřmalarda bazı durumlarda etkin znelikler kullanılmasına rađmen znelik matrisinin boyutları ok byk olabilmektedir. znelik matrisinin yksek boyutlara sahip olması sistem performansını olumsuz ynde etkilemektedir. Bu nedenle bir ok alıřmada sınıflandırma iřlemi iin yetersiz olan zneliklerin ıkarılması iin boyut azaltma algoritmaları veya etkin znelik seim algoritmaları kullanılmaktadır. Boyut azaltma algoritmaları, birbirileri ile yksek korelasyona sahip zneliklerin, ierisindeki bilginin byk bir kısmını kaybetmeden boyutunu azaltabilen

yöntemlerdir (Der Maaten ve Postma 2009). Literatürde sıklıkla kullanılan boyut azaltma yöntemleri; temel bileşen analizi (Siuly ve Li 2015, Chai ve ark. 2016), faktör analizi (Engemann ve Gramfort 2015, Shoorangiz ve ark. 2017), doğrusal ayırım analizi (Zhou ve ark. 2013), raslantısal komşuluk yerleştirme analizi (Yapıcı ve ark. 2018), maksimum daralan metrik öğrenme analizi (Yapıcı ve ark. 2018) vb. olarak sıralanmaktadır.

Etkin öznitelik seçim algoritmalarında boyut azaltma yöntemlerinde olduğu gibi yetersiz özniteliklerin sistemden çıkarılmasına dayanmaktadır. Literatürde sıklıkla kullanılan öznitelik seçme algoritmaları; ki-kare yöntemi, bilgi kazancı yöntemi, kazanım oranı hesapları, gini katsayısı hesapları, OneR kuralı, Relief yöntemi, ileri yönde öznitelik seçimi, geri yönde öznitelik seçimi ve genetik algoritmaları olarak sıralanmaktadır (Suto ve ark. 2016, Huijuan ve ark. 2017, Kaynar ve ark. 2018).

Literatürde EEG işaretleri kullanılarak hastalık tespitine yönelik birçok çalışma mevcuttur. Bunlardan biri Vidyaratne ve Iftekharuddin'in yapmış olduğu gerçek zamanlı epileptik nöbet tespiti sistemidir. Araştırmacılar çalışmasında, kafa derisi ve kafa içi elektrotlar ile aldıkları EEG sinyallerini kullanarak epileptik nöbet başlangıç anını tespit etmektedir. EEG işaretlerinin harmonik dalgacık paket dönüşümü (harmonic wavelet packet transform) ve fraktal boyut (fractal dimension) özellikleri kullanılarak bu tespit gerçekleştirilmektedir. Çalışmada kısa süreli EEG işaretleri (veri seti-A) ve uzun süreli EEG işaretleri (veri seti-B) toplanarak iki ayrı veri seti oluşturulmuştur. Kısa süreli EEG işaretleri kullanılarak yapılan sınıflandırma sonucu % 99.8 sınıflandırma başarısı elde edilmiştir. Önerilen algoritmanın, % 96 duyarlılık (sensitivity) oranı ile saat başına 0.1 medyan yanlış algılama oranı ve 1.89 sn ortalama algılama gecikmesi ile nöbet başlangıç tespiti için etkili olduğu gösterilmiştir (Vidyaratne ve Iftekharuddin 2017).

Farklı düşünsel ve görsel görevler karşısında kaydedilen EEG işaretlerinin sınıflandırılması BBA uygulamalarında çok önemli bir konudur. Sınıflandırma işleminin hızlı ve doğru olması beklenmektedir. Literatürde yapılan çalışmalarda pek çok farklı sınıflandırıcı yöntemi kullanılmaktadır. Bu yöntemlere örnek olarak makine öğrenmesi tabanlı sınıflandırıcılardan; k-en yakın komşuluk algoritması (k-EYK), destek vektör makineleri (DVM), doğrusal ayırışım analizi (DAA), böl ve fethet algoritması (BFA),

rastgele orman karar ağacı algoritmaları (ROKA), bayes sınıflandırıcısı (BS) ve derin öğrenme tabanlı sınıflandırıcılardan; yapay sinir ağları (YSA), derin sinir ağları (DSA), evrişimsel sinir ağları (ESA), yineleyen sinir ağları (YSA), uzun-kısa süreli bellek sinir ağları verilebilmektedir.

Sınıflandırıcı algoritmalarının kendine özgü avantaj ve dezavantajları olduğu için, her sınıflandırıcı aynı uygulama için farklı sonuçlar verebilmektedir (Lotte ve ark 2007). Makine öğrenmesi tabanlı sınıflandırıcılardan; k-EYK, DVM ve DAA uygulanması kolay ve hızlı sonuç veren algoritmalar olduğu için makine öğrenmesi çalışmalarında sıklıkla tercih edilmektedir (Murugavel ve Ramakrishnan 2015, Mehmood ve Lee 2015, Dhongade ve Rao 2017). Günümüz modern sınıflandırıcıları olarak kabul edilen derin sinir ağları ise görüntü işleme ve ses işleme alanları başta olmak üzere doğal dil işleme ve biyomedikal gibi bir çok farklı alanda uygulanmaktadır (Ma ve ark. 2015, Shamwell ve ark. 2016, Tang ve ark. 2017).

Literatürdeki BBA uygulamaları çalışmalarının bir çoğu iki sınıflı sınıflandırma problemlerini ele almaktadır (Vidyaratne ve Iftekharuddin 2017, Amin ve ark. 2015, Singh ve ark. 2016). Makine öğrenmesi uygulamalarında sınıf sayısı arttıkça problem karmaşılaşmakta ve sisteme ait sınıflandırma başarısı azalmaktadır (Aydemir ve Kayıkçıoğlu 2010).

Memar ve Faradji'nin 2018 yılında yapmış olduğu çalışmada her bir EEG ritmi sekiz alt sınıfa (delta, teta, alfa, sigma, beta-1, beta-2, gama-1, gama-2) ayrılmıştır. Deney için 25 uyku düzensizliğine sahip hasta ve 20 sağlıklı birey gönüllü olarak EEG kaydı vermiştir. Her bir alt frekans bandı için on üç öznitelik çıkarılarak toplam öznitelik matrisi 104 öznitelikten oluşturulmuştur. Çalışmada minimum yedeklilik-maksimum uygunluk özellik seçim algoritması (the minimal-redundancy-maximal-relevance feature selection algorithm) kullanılarak gereksiz öznitelikler çıkarılmıştır. Boyutu azaltılmış öznitelik matrisi rastgele orman karar ağacı algoritması kullanılarak sınıflandırılmıştır. Ayrıca sınıflandırma işleminde için 5-kat çapraz doğrulama yöntemi kullanılmıştır. Çalışma sonucunda önerilen sisteme ait sınıflandırma başarısı % 95.31 olarak elde edilmiştir (Memar ve Faradji 2018).

Literatürde EEG tabanlı BBA sistemlerinin bir diğerk kullanım alanı sürücü yorgunluk tespit sistemleridir. Trafik kazalarının en önemli nedeni olarak sürücülerin uykusuzluğu ve yorgunluğu gösterilmektedir. Bu nedenle sürücü performansının analizi konusunda yapılan arařtırmalar büyük önem taşımaktadır. Sürücü yorgunluğu, nörobiyolojik süreçlerden kaynaklı uyuşukluğa ve uykululuğa neden olmaktadır. EEG, insan beynindeki nörofizyolojik aktiviteyi doğrudan ölçtüğü için yorgunluğu tespit etmek için önemli ve güvenilir bir yöntem olarak kabul edilmektedir (Hong ve ark. 2005).

Literatürde bu amaç doğrultusunda yapılmış bir çok çalışma mevcuttur. Bunlardan biri Wang ve diğerklerinin 2018 yılında yapmış olduđu gerçek zamanlı sürücü yorgunluk tespit sistemidir. Çalışmada on sağlıklı birey sürüş simülatörü ile 90 dk araç kullanırken EEG kayıtları alınmıştır. EEG sinyallerinin teta, alfa ve bata frekans bandı bileşenlerine güç spektral yoğunluğu ve örnek entropi deęerleri öznitelik olarak uygulanmıştır. Çalışma sonucunda sürücü yorgunluğu başlama evresinde başarılı bir şekilde tespit edilmiştir (Wang ve ark. 2018).

BBA uygulamaları alanında ileri gelen bazı arařtırma toplulukları belirli yıllarda yarışmalar düzenlemektedir. Bunlardan en çok bilineni “BCI Competitions” yarışmalarıdır. Bu yarışmalarda farklı sınıflandırma ve regresyon problemlerine sahip EEG kayıtları katılımcılara verilerek ilgili problemin çözümlenmesi istenmektedir. Veriler aynı zamanda yarışma tamamlandıktan sonrada web sitesinde arařtırmacıların çalışmaları için açık kaynak olarak sunulmaktadır. Bu sayede arařtırmacılar, elde edilen sınıflandırma başarılarını arttırmak ve bilimsel çalışmalarında kullanmak amacıyla veri setlerini kullanabilmektedir (Doroshenkov ve ark. 2007, Aydemir ve Kayıkçiođlu 2011, Xu ve ark. 2018, Guan ve ark. 2019).

2.4. Tezin Kapsamı ve Konusu

Bu tez çalışmasında, EEG işaretlerinin sınıflandırılması işlemi için sınıflandırma başarısı yüksek ve hızlı bir yaklaşım önerilmiştir. Çalışmada veri seti olarak “BCI Competition II” yarışmasında sunulan III numaralı EEG kayıtları kullanılmıştır. Bu veri seti, bilgisayar ekranında çıkan artı “+” işaretinin sağa veya sola doğru hareketinin hayal edilmesi ile toplanan EEG işaretlerinden oluşmaktadır. Tezin üçüncü bölümünde veri setinin tanıtımı detaylı olarak verilmiştir.

EEG işaretleri içerisindeki fiziksel ve çevresel gürültü kaynaklarının etkisini oradan kaldırmak için verilere ön işleme işlemleri uygulanmıştır. Sonrasında, EEG işaretlerini en iyi şekilde ifade edecek özniteliklerin (fourier dönüşümü, dalgacık dönüşümü, ortalama türev, hjort parametreleri, hilbert dönüşümü vb.) elde edilebilmesi için on farklı öznitelik grubu verilere uygulanmış ve en yüksek sınıflandırma başarısını sağlayan grup seçilmiştir.

Yüksek boyutlu öznitelik matrisinin boyutunun azaltılması ve içerisindeki yetersiz özniteliklerin seçilebilmesi için Ardışık İleri Yönde Seçim Algoritması kullanılmıştır. Sınıflandırma işlemi için, makine öğrenmesi tabanlı klasik sınıflandırıcılardan; k-en yakın komşuluk, destek vektör makineleri, doğrusal ayırım analizi algoritmaları ve derin öğrenme tabanlı sınıflandırıcılardan; derin sinir ağları kullanılmıştır. Bu sayede, makine öğrenmesi tabanlı klasik sınıflandırıcılar ve derin öğrenme tabanlı sınıflandırıcıların sınıflandırma başarımları karşılaştırılmıştır. Ön işleme, öznitelik çıkarma ve sınıflandırma işlemlerinin matematiksel teorisi “Materyal ve Metot” başlığı altında detaylandırılmıştır.

“Bulgular” bölümünde EEG işaretlerinin sınıflandırılması sonucu elde edilen sınıflandırma başarımları verilmiştir. “Sonuçlar” bölümünde ise çalışma sonucunda elde edilen bulgular yorumlanmış ve literatürde yapılmış olan mevcut BBA çalışmaları sonuçları ile karşılaştırılmıştır.

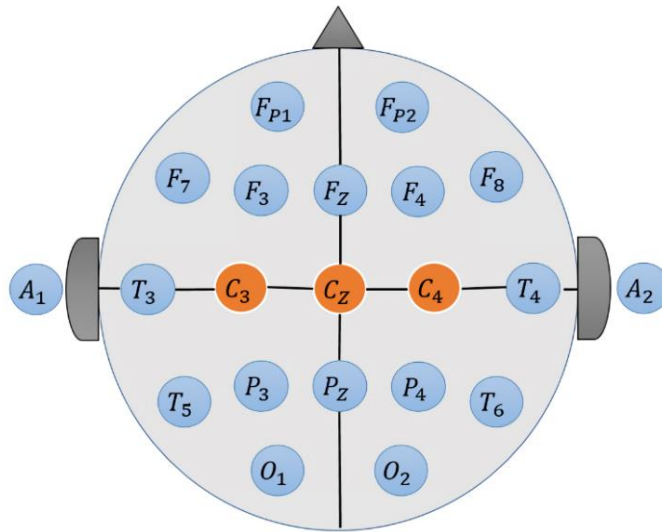
3. MATERYAL ve YÖNTEM

Bu bölümde; çalışmada kullanılan veri setinin açıklanması, ön işleme yöntemleri, öznitelik çıkarma yöntemleri, makine öğrenmesi tabanlı klasik sınıflandırma yöntemleri ve derin öğrenme tabanlı sınıflandırıcı yöntemleri detaylandırılmıştır.

3.1. Kullanılan Veri Setinin Açıklanması - BCI Competitions II Veri Seti

“BCI Competition” yarışmaları, katılımcıların sinyal işleme ve sınıflandırma yöntemlerini kullanarak en iyi beyin-bilgisayar arayüzü sistemini oluşturmasını amaçlayan bir organizasyonlardır. Bu amaçla, belirli dönemlerde yarışma sayfasına farklı sınıflandırma problemlerine sahip veri setleri yüklenmektedir. Yarışma sonrasında ilgili BCI sistemlerinin iyileştirilebilmesi ve bilimsel çalışmaların yapılabilmesi amacıyla veri setlerinin kullanımını açık kaynak olarak devam etmektedir.

Bu tez çalışmasında, birinci veri seti olarak “BCI Competition II” yarışmasında sunulan III numaralı EEG kayıtları kullanılmıştır. Veri seti Graz Teknoloji Üniversitesi, Biyomedikal Mühendisliği Enstitüsü, Tıbbi Bilişim Bölümü üyesi Dr. Alois Schlögl ve ekibi tarafından oluşturulmuştur (URL-1). EEG işaretlerinin ölçülmesi için deneklerin kafa derisine üç adet Ag-AgCl elektrot yerleştirilmiştir. İlgili elektrot lokasyonları Şekil 3.1’ de verilmektedir.

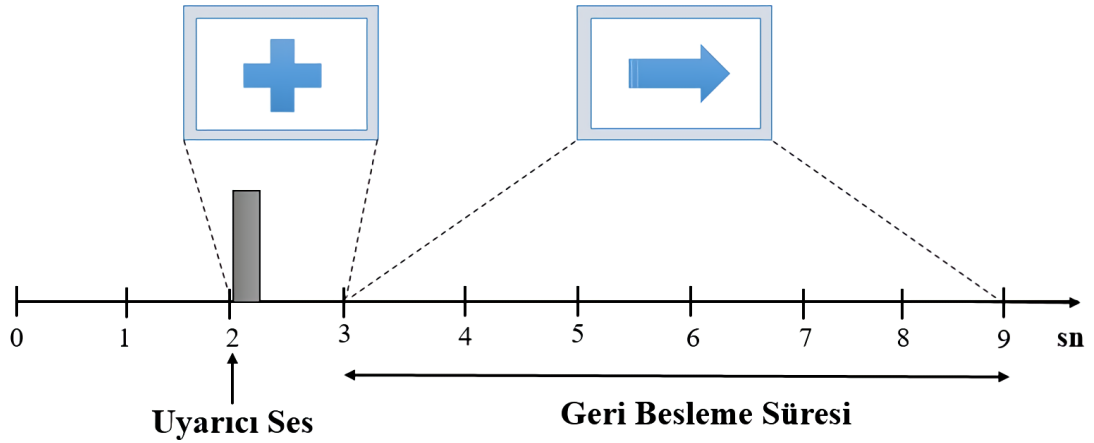


Şekil 3.1. Veriseti-I elektrot lokasyonları.

Elektrot lokasyonları; merkezi sulkus bölgesi ortasına yerleştirilmiş elektrot (C_2), merkezi sulkus bölgesi soluna yerleştirilmiş (sol yarım küre) elektrot (C_3) ve merkezi sulkus bölgesi sağına yerleştirilmiş (sağ yarım küre) elektrot (C_4) olarak sıralanmaktadır.

EEG kayıtları G.Tec firmasına ait bir kuvvetlendirici kullanılarak gerçekleştirilmiştir. İşaretler 128 Hz örnekleme frekansı ile örneklenmiştir. Ayrıca işaretler, alt kesim frekansı 0.5 Hz ve üst kesim frekansı 30 Hz olan band geçiren bir filtreden geçirilmiştir.

Veri seti içerisinde toplam 280 adet deney verisi bulunmaktadır. Bunlardan 140 adedi eğitim verisi, 140 adedi test verisi olarak kaydedilmiştir. Tüm deneylere ait sınıf bilgiside veri seti içerisinde verilmektedir (Neuper ve ark. 1994). Deneyler gerçekleştirilirken kullanılan senaryo Şekil 3.2' de verilmektedir.



Şekil 3.2. Veriseti-I deney prosedürü.

Veri seti içerisinde bulunan EEG işaretlerinin elde edilmesi için gerçekleştirilen deneyde, ilk iki saniye deneğe karanlık bir ekran gösterilmiştir. İkinci saniyede bilgisayardan uyarıcı bir ses verilerek deneyin başladığı belirtilmiştir. Daha sonra bilgisayar ekranında iki-üç saniye aralığında " + " işareti gösterilmiştir. Üç-dokuz saniye aralığında denekten, ekranda çıkan ok yönünde artı işaretinin hareket ettiğini hayal etmesi istenmiştir. Dokuzuncu saniyeye ulaşıldığında EEG kayıtları tamamlanmıştır (Schlögl ve ark. 1997).

3.2. Ön İşleme Yöntemleri

Bu tez çalışmasında, veriler ön işleme adımlarında ilk olarak normalize edilmiş ve ardından alt frekans bandlarına ayrılmıştır.

3.2.1. Normalizasyon

Normalizasyon işlemi, EEG işaretleri içerisindeki gürültü kaynaklı bozuklukların belirli oranda ortadan kaldırılabilmesi ve işaretlerin bütünü standartlaştırılması amacıyla sinyal işleme uygulamalarında sıklıkla kullanılmaktadır. Standart sapma normalizasyonu, bu uygulamalarda en çok kullanılan yöntemdir.

Standart sapma normalizasyonu, verinin ortalama değerinin tüm elemanlarından çıkarılması ve birim standart sapma değerine oranlanması sonucu veriyi standartlaştırmaktadır. Bu işlemin matematiksel ifadesi Denklem 3.1’de verilmektedir.

$$\hat{V}(n, t) = \frac{V(n, t) - \bar{V}(n, t)}{\sigma_n} \quad (3.1)$$

Bu denklemde, $V(n, t)$ orjinal EEG işaretini (n: Kanal, t: Örnek) temsil etmektedir. $\bar{V}(n, t)$ verinin ortalamasını ve σ_n verinin standart sapmasını ifade etmektedir.

3.2.2. EEG işaretlerinin alt frekans bandlarına ayrılması

EEG işaretleri, beyinde gerçekleşen işlemlerin temelinde yatan bilgiyi içerisinde barındıran, farklı frekans değerlerindeki işaretlerdir. Frekans aralığı 0.5 Hz-50 Hz arasında olan EEG sinyallerini farklı frekans bandlarında incelemek için filtreleme işlemleri yapılmaktadır. Filtreleme sonucunda; Delta (0.5-4 Hz), Teta (4-8 Hz), Alfa (9-13 Hz), Beta (14-31 Hz) ve Gama (32-50 Hz) frekans bandları oluşmaktadır (Kumar ve Bhuvanewari 2012).

Bu tez çalışması kapsamında, EEG işaretleri band geçiren sonlu darbe cevaplı filtreden geçirilmiştir. Delta frekans bandı için alt kesim frekansı 0.5 Hz üst kesim frekansı 4 Hz, teta frekans bandı için alt kesim frekansı 4 Hz üst kesim frekansı 8 Hz, alfa frekans bandı

için alt kesim frekansı 9 Hz üst kesim frekansı 13 Hz, beta frekans bandı için alt kesim frekansı 14 Hz üst kesim frekansı 31 Hz ve gama frekans bandı için alt kesim frekansı 32 Hz üst kesim frekansı 50 Hz olan band geçiren filtreler kullanılmıştır. Filtre karakteristikleri MATLAB® ortamında tasarlanmıştır.

3.3. Öznitelik Çıkarma Yöntemleri

EEG işaretlerini en iyi şekilde temsil edebilecek özniteliklerin çıkarılması, sınıflandırma başarımına etki eden en önemli faktörlerden biridir. Bu tez çalışmasında, EEG işaretleri içerisindeki bilgiyi en iyi şekilde ifade edebilecek öznitelikleri belirlemek amacıyla on farklı öznitelik grubu veriye uygulanmış ve sonuçlar değerlendirilmiştir. Uygulanan özniteliklerin içerikleri Çizelge 3.1’ de verilmektedir.

Çizelge 3.1. EEG işaretlerine uygulanan öznitelik grupları

Öznitelik	Uygulanan Öznitelik İçerikleri
<i>Öznitelik-1</i>	Ortalama, Varyans, Maksimum, Basıklık, Çarpıklık, Norm, Hjorth Parametreleri (Aktivite, Hareketlilik, Karşıtlık) Değerleri
<i>Öznitelik-2</i>	Temel Bileşen Analizi ile İlintisiz Hale Gelen Verinin Ortalama, Varyans, Maksimum, Kurtosis, Skewness, Norm, Hjorth Parametreleri (Aktivite, Hareketlilik, Karşıtlık) Değerleri
<i>Öznitelik-3</i>	Fourier Dönüşümü Alınmış İşaretin Standart Sapması, Ortalamasının Normu, Varyansının Normu
<i>Öznitelik-4</i>	Temel Bileşen Analizi ile İlintisiz Hale Gelmiş ve Fourier Dönüşümü Alınmış İşaretin Standart Sapması, Ortalamasının Normu, Varyansının Normu
<i>Öznitelik-5</i>	Dalgacık Dönüşümü Uygulanmış İşaretin Ortalaması, Standart Sapması, Basıklık, Çarpıklık
<i>Öznitelik-6</i>	Temel Bileşen Analizi ile İlintisiz Hale Gelmiş ve Dalgacık Dönüşümü Uygulanmış İşaretin Ortalaması, Standart Sapması, Basıklık, Çarpıklık
<i>Öznitelik-7</i>	Hilbert Dönüşümü Uygulanmış İşaretin Gerçek Kısımının Ortalaması ve Standart Sapması, Sanal Kısımının Ortalaması ve Standart Sapması

Çizelge 3.1. EEG işaretlerine uygulanan öznitelik grupları (devam)

Öznitelik	Uygulanan Öznitelik İçerikleri
Öznitelik-8	Temel Bileşen Analizi ile İlintisiz Hale Gelmiş, Hilbert Dönüşümü Uygulanmış İşaretin Gerçek Kısmının Ortalaması ve Standart Sapması, Sanal Kısmının Ortalaması ve Standart Sapması
Öznitelik-9	Öznitelik-3 + Öznitelik-5 + Öznitelik-7 (Frekans Tabanlı Karma Öznitelik Grubu)
Öznitelik-10	Temel Bileşen Analizi ile İlintisiz Hale Gelmiş, Öznitelik-3 + Öznitelik-5 + Öznitelik-7 (Frekans Tabanlı Karma Öznitelik Grubu)

Öznitelik grupları, literatürde sıklıkla kullanılan EEG özellikleri baz alınarak oluşturulmuştur. Aşağıda, EEG işaretlerini temsil etmek için kullanılan özniteliklerden Fourier Dönüşümü, Dalgacık Dönüşümü ve Hilbert Dönüşümü matematiksel altyapısı detaylandırılmıştır.

3.3.1. Fourier dönüşümü yöntemi

Fourier Dönüşümü, EEG işaretlerinin temsil edilebilmesi için çalışmalarda sıklıkla kullanılan frekans tabanlı bir dönüşüm yöntemidir (Hayes 1998). Bu yöntem ile zaman bölgesinde tanımlı olan sinyallerin kapsadığı frekanslar gösterilerek işaretler frekans bölgesinde ifade edilmektedir. İşaretleri temsil eden fonksiyonların seriler cinsinden açılabilmesi, sinyal içerisindeki anlamlı bilgilerin elde edilmesine olanak sağlamaktadır (Demren 2015). $x(t)$ zaman domeninde değişen bir işaret olmak üzere $x(t)$ işaretinin Fourier Dönüşümü Denklem 3.2’de verilmektedir.

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (3.2)$$

$x(t)$ periyodik işaretin Fourier Dönüşümünün alınabilmesi için işaretin; sınırlı olması, sonlu sayıda süreksizlik noktası olması, sınırlı sayıda maksimum ve minimumu olması ve sınırlı sayıda ortalama değere sahip olması gerekmektedir.

$f(x)$, $-a \leq x \leq a$ aralığında deęişen $2a$ periyotlu ve x deęişkenine baęlı bir fonksiyon olmak üzere $f(x)$ iřaretinin Fourier Serisi açılımını Denklem 3.3 ile ifade edilmektedir.

$$f(x) = a_0 + \sum_{n=1}^{\infty} \left(a_n \left[\cos \frac{n\pi x}{a} \right] + b_n \left[\sin \frac{n\pi x}{a} \right] \right) \quad (3.3)$$

Fourier Dönüřümü problemleri, Denklem 3.2’de verilen Fourier Serisi açılımının katsayıları olan a_0 , a_n ve b_n katsayılarının elde edilmesi ile çözümlenmektedir. Bu katsatılara aynı zamanda Fourier katsayıları denilir. Euler baęıntısı yardımıyla elde edilen Fourier katsayıları Denklem 3.4’te verilen formüller ile elde edilmektedir.

$$a_0 = \frac{1}{2a} \int_{-a}^a f(x) dx \quad (3.4a)$$

$$a_n = \frac{1}{2a} \int_{-a}^a f(x) \cos \left[\frac{n\pi x}{a} \right] dx \quad (3.4b)$$

$$b_n = \frac{1}{2a} \int_{-a}^a f(x) \sin \left[\frac{n\pi x}{a} \right] dx \quad (3.4c)$$

Fourier katsayıları $f(x)$ fonksiyonun, sinüs ve kosinüs taban fonksiyonlarından oluşan fonksiyon uzayına izdüřürölmüş halini oluřturmaktadır. Bu iřlem Denklem 3.4 grubunda göröldüęü gibi, iç çarpımlar yardımıyla yapılmaktadır. İřlem sonucunda, $f(x)$ fonksiyonunu harmonik taban fonksiyonları cinsinden ifade edecek katsayılar elde edilmektedir (Demren 2015).

Fourier Dönüřümü her ne kadar sürekli bir dönüřüm yöntemi olsada, pratikte yapılan uygulamalarda ayrık veri noktaları kullanılarak çalıřılmaktadır. Bu nedenle Fourier Dönüřümü yöntemlerinin yanı sıra Ayrık Fourier Dönüřümü yöntemleride ortaya konulmaktadır. f , sıfırdan N ’ye kadar örnek noktası bulunan bir dizi olmak üzere f ayrık sinyalinin Ayrık Fourier Dönüřümü Denklem 3.5 ile ifade edilmektedir.

$$\hat{f}_k = \sum_0^{N-1} f_n e^{\frac{-2\pi ink}{N}} \quad (3.5)$$

Bu denklemde; f_n , f ayrık işaretinin $t = t_n$ anındaki değerini ve k bir tamsayıyı ifade etmektedir. Ayrık Fourier Dönüşümünün ayrık işaretler ile çalışmaya uygun olup olmadığı, sürekli işaretten örneklenmesi sonucu oluşan ayrık veri noktaları tekrardan bir araya getirildiğinde orjinal işarete yakınlığı ile test edilebilmektedir.

3.3.2. Dalgacık dönüşümü yöntemi

Zaman domeninde tanımlanmış işaretler, genlik ve zaman olmak üzere iki bilgi barındırmaktadır. Genlik ve zaman değerleri bazen işaret içerisindeki asıl bilginin anlaşılabilmesi için yeterli olmamaktadır. İşaret içerisindeki gerekli bu bilgi, sinyalin içerdiği frekanslarda saklı olabilmektedir. Böyle durumlarda işaretler zaman-genlik domeninde incelenmek yerine frekans domeninde incelenmektedir. Frekans domeninde tanımlanmış işaretler, farklı frekans bileşenleri ve bu frekans bileşenlerine ait genlik bilgisini barındırmaktadır. Sinyal işleme uygulamalarında işaret içerisindeki frekans bilgisinin ortaya çıkarılabilmesi için frekans tabanlı analizlerden biri olan Dalgacık Dönüşümü yöntemi geliştirilmiştir.

Dalgacık Dönüşümü yöntemi, analiz edilecek $x(t)$ işareti ile genişliği değiştirilebilen bir dalgacık fonksiyonunun evrişimi ile tanımlanmaktadır. Dalgacık fonksiyonu $\psi(t)$ ile ifade edilmektedir. $\psi(t)$ düşük frekanslar için geniş pencere boyutlarına sahipken, yüksek frekanslarda dar bir pencere boyutuna sahiptir. Bu sadece tüm frekans değerlerinde en iyi zaman-frekans çözünürlüğü sağlanmaktadır (Adeli ve ark. 2003). Dalgacık fonksiyonu Denklem 3.6 ile ifade edilmektedir.

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi \left[\frac{t-u}{s} \right] \quad (3.6)$$

Bu denklemde u öteleme miktarını, s ölçeklendirme miktarını ve t zamanı ifade etmektedir. Literatürde sıklıkla kullanılan dalgacık fonksiyonları Morlet, Daubechies,

Haar, Mexican Hat ve Gabor dalgacıkları olarak sıralanmaktadır. İlgili dalgacıkların matematiksel ifadeleri Çizelge 3.2’ de verilmektedir.

Çizelge 3.2. Dalgacık fonksiyonları matematiksel ifadeleri

Dalgacık Fonksiyonu	Matematiksel İfadesi
Morlet Dalgacıđı	$\psi(t) = e^{-t^2} \cos(\pi\sqrt{2/\ln 2} t)$
Daubechies Dalgacıđı	$\psi(t) = 2^{j/2} \psi(2^j t - k)$ 2^j : Ölçekleme k : Merkez Nokta
Haar Dalgacıđı	$\psi(t) = \begin{cases} -1, & 0 \leq t < 1/2 \\ +1, & 1/2 \leq t < 1 \\ 0, & \text{diđer durumlar} \end{cases}$
Mexican Hat Dalgacıđı	$\psi(t) = (2/\sqrt{3})\pi^{-1/4}(1 - t^2) \exp(-t^2/2)$
Gabor Dalgacıđı	$\psi(t) = \exp(-t^2/2\sigma^2) \exp(jkt)$

Haar dalgacıđı, en eski, basit ve küçük dalgacık fonksiyonudur. Ortogonal, biortogonal ve simetrik bir dalgacıđtır. Daubechies dalgacıđı, ölçeklendirme fonksiyonuna sahip bir dalgacıđtır. Haar dalgacıđı gibi ortogonal ve biortogonal özelliklerine sahiptir. Fakat simetrik bir fonksiyon değildir. Mexican Hat dalgacıđı, ortogonal ve biortogonal değildir. Ölçeklendirme fonksiyonu mevcut değildir. Morlet dalgacıđı ise ortogonal ve biortogonal değildir. Ölçeklendirme fonksiyonu yoktur. Ayrıca simetrik bir fonksiyondur. Morlet dalgacıđı, EEG işaretleri ile benzerliđi bulunması sebebiyle öznitelik çıkarma işlemlerinde sıklıkla kullanılmaktadır (Semmlow 2004). $\psi(t)$ dalgacık fonksiyonun $x(t)$ işareti ile evrişimi Denklem 3.7’de verilmektedir.

$$\text{Dalgacık - Dönüşümü } \psi_x(u, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^* \left[\frac{t-u}{s} \right] dt \quad (3.7)$$

Bu denklem kullanılarak dalgacık katsayıları kümesi elde edilmektedir. Bu katsayılar sinyal ile temel fonksiyon arasındaki benzerliđin bir ölçütüdür.

3.3.3. Hilbert dönüşümü yöntemi

Hilbert dönüşümü; zamanla değişen bir $s(t)$ sinyalinin, genliğinde herhangi bir değişim meydana gelmeden fazının $\pi/2$ kadar kaydırılması olarak tanımlanmaktadır. İşaretin fazının $\pi/2$ kadar kaydırılması işlemi, $s(t)$ sinyalinin $1/\pi t$ ile konvolüsyonu sonucu gerçekleşmektedir. Denklem 3.8'de Hilbert Dönüşümü ifadesi verilmektedir.

$$\text{Hilbert - Dönüşümü } \{s(t)\} = \hat{s}(t) = s(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(u)}{t-u} du \quad (3.7)$$

Bu denklemde $\hat{s}(t)$, $s(t)$ sinyalinin Hilbert Dönüşümü sonucu oluşan çıkışı temsil etmektedir. $\hat{s}(t)$ ifadesi sanal ve gerçek kısımdan oluşan bir karmaşık sayıdır. ' x ' sinyalinin gerçek kısmını, ' y ' ise sanal kısmını temsil etmek üzere $\hat{s}(t)$ işareti Denklem 3.8 ile gösterilmektedir.

$$\hat{s}(t) = x + jy \quad (3.7)$$

Karmaşık sayıların öznitelik olarak kullanılması sistem performansını yavaşlatması ve işlem karmaşasını arttırması sebebiyle yapılan çalışmalarda tercih edilmemektedir. $\hat{s}(t)$ eşitliğinin ' t ' sayıda örnekten oluşması durumunda, gerçek kısmının (x) ortalaması ve standart sapması, sanal kısmının (y) ortalaması ve standart sapması Denklem 3.8 grubunda verilmektedir.

$$G_{ort} = \frac{x_1 + x_2 + x_3 + \dots + x_t}{t} \quad (3.8a)$$

$$S_{ort} = \frac{y_1 + y_2 + y_3 + \dots + y_t}{t} \quad (3.8b)$$

$$G_{std} = \sqrt{\frac{(x_1 - G_{ort})^2 + (x_2 - G_{ort})^2 + \dots + (x_t - G_{ort})^2}{t-1}} \quad (3.8c)$$

$$S_{std} = \sqrt{\frac{(y_1 - S_{ort})^2 + (y_2 - S_{ort})^2 + \dots + (y_t - S_{ort})^2}{t - 1}} \quad (3.8d)$$

Denklem 3.8' da verilen

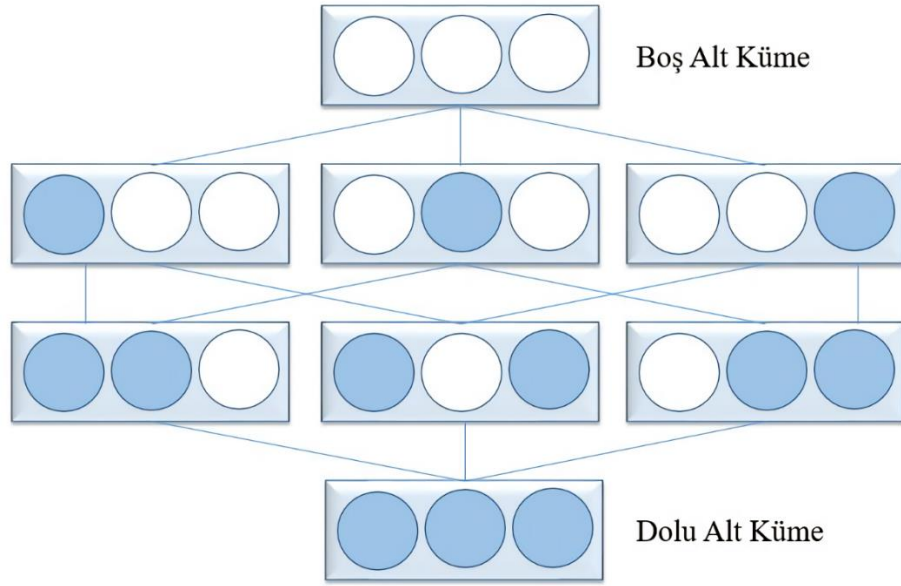
- ✚ G_{ort} ifadesi $\hat{s}(t)$ işaretinin gerçek kısmının ortalamasını,
- ✚ S_{ort} ifadesi $\hat{s}(t)$ işaretinin sanal kısmının ortalamasını,
- ✚ G_{std} ifadesi $\hat{s}(t)$ işaretinin gerçek kısmının standart sapmasını
- ✚ S_{std} ifadesi $\hat{s}(t)$ işaretinin sanal kısmının standart sapmasını temsil etmektedir.

3.4. Ardışık İleri Yönde Seçim Algoritması

Sınıflandırma problemlerinde, sınıfları birbirinden ayırt etmek için kullanılan özniteliklerin tamamı her zaman iyi sonuç vermemektedir. Sınıfları ayırt etmek için yetersiz olan öznitelikler, sınıflandırma doğruluğunu düşürmektedir. Ayrıca öznitelik matrisinin boyutunun artması, sistem performansını da olumsuz yönde etkilemektedir. Bu nedenle öznitelik matrisi içerisinde yer alan yetersiz özniteliklerin sistemden çıkarılması, sistemin başarısını yükseltecektir (Nasr ve ark. 2017). Bu tez çalışmasında etkin öznitelik seçme yöntemi olarak Ardışık İleri Yönde Seçim Algoritması kullanılmıştır.

Ardışık ileri yönde seçim algoritması, öznitelik seçimi için literatürde kullanılan etkili bir yöntemdir. Bu algorithmada boş öznitelik alt kümesinden başlanarak öznitelik değerlerinin olası tüm kombinasyonları, dolu alt kümeye kadar üretilmekte ve en yüksek sınıflandırma başarısına sahip olan öznitelik grubu seçilmektedir (Nasr ve ark. 2017).

Ardışık ileri yönde seçim algoritmasının üç adet öznitelik için oluşturulan kafes yapısı Şekil 3.3' te verilmektedir.



Şekil 3.3. Ardışık ileri seçim algoritması kafes yapısı.

Üç adet öznitelik için oluşturulan kafes yapısı boş öznitelik grubu ile başlamaktadır. Devamında sırasıyla aşağıdaki öznitelik gruplarının performansı analiz edilmektedir.

✚ Özniteliklerin Tekli Kombinasyonları:

- ❖ Sadece 1 numaralı öznitelik ile sistem performansının analizi
- ❖ Sadece 2 numaralı öznitelik ile sistem performansının analizi
- ❖ Sadece 3 numaralı öznitelik ile sistem performansının analizi

✚ Özniteliklerin İkili Kombinasyonları:

- ❖ 1 ve 2 numaralı öznitelikler ile sistem performansının analizi
- ❖ 1 ve 3 numaralı öznitelikler ile sistem performansının analizi
- ❖ 2 ve 3 numaralı öznitelikler ile sistem performansının analizi

✚ Özniteliklerin Üçlü Kombinasyonu:

- ❖ 1, 2 ve 3 numaralı öznitelikler ile sistem performansının analizi

Özniteliklerin farklı kombinasyonları sonucu oluşan yedi farklı durum için sistemin sınıflandırma doğrulukları hesaplanmaktadır. Elde edilen sonuçlar karşılaştırılarak, en yüksek sınıflandırma başarısına sahip öznitelik kombinasyonu sistemde kullanılmak üzere tercih edilmektedir. Bu şekilde yetersiz öznitelikler atılarak, etkin öznitelikler ile sistem performansı yükseltilmektedir.


3.5. Makine Öğrenmesi Tabanlı Klasik Sınıflandırma Yöntemleri

Bu tez çalışmasında, makine öğrenmesi tabanlı denetimli sınıflandırıcılardan k-En Yakın Komşuluk Algoritması, Destek Vektör Makineleri ve Doğrusal Ayırım Algoritması kullanılmıştır.

3.5.1. k-en yakın komşuluk algoritması

k-En Yakın Komşuluk Algoritması (k-EYK); sınıf bilgisi bilinmeyen bir test örneğine, kendisine en yakın 'k' adet eğitim örneğinin etiketine bakarak sınıf tayin edilmesi işlemi olarak tanımlanmaktadır (Duda ve ark. 2001). Kullanımı basit ve etkin olması sebebiyle BBA uygulamalarında sıklıkla tercih edilmektedir.

Test örneğinin sınıfının tayin edilebilmesi için eğitim ve test örneğinin öznitelik vektörü kullanılarak saçılım grafiği çizilmektedir. İlgili test örneğine en yakın 'k' adet eğitim örneği seçilmekte ve aralarındaki uzaklık hesaplanmaktadır. Sınıflandırma işlemi için, test örneğine en yakın 'k' adet eğitim örneğinin sınıflarına bakılarak sayıca fazla olan sınıf tespit edilmektedir. Tespit edilen bu sınıf test örneğinin sınıfı olarak tayin edilmektedir. Şekil 3.4' te iki öznitelik değerine sahip ve üç sınıflı bir problemin saçılım grafiği verilmiştir. Örnekte $k = 5$ olarak seçilmiş ve sınıf bilgisi bilinmeyen test örneği etiketlenmiştir.



Şekil 3.4. k-EYK Algoritması için örnek.

Sınıf bilgisi bulunmayan test örneği, $k = 5$ seçimine göre kendisine en yakın beş eğitim verisi içinden bir tanesi “ 1 numaralı sınıf ”, bir tanesi “ 2 numaralı sınıf ” ve üç tanesi “ 3 numaralı sınıf ” verisine daha yakın olduğu için k-EYK Algoritmasına göre 3 numaralı sınıf ile etiketlenmiştir.

k-EYK Algoritmasında k değerinin seçimi sınıflandırma performansını açısından büyük önem taşımaktadır. Uygulamalarda genellikle ‘k’ değeri, tek sayı olarak seçilmektedir. Bunun sebebi çift sayı seçilmesi durumunda sınıflar arası eşitlik durumunun oluşması ihtimalidir. Ayrıca bu algorithmada ‘k’ sayısı kadar eğitim örneğine olan uzaklık hesaplanırken farklı uzaklık fonksiyonları kullanılabilir. Bu fonksiyonlara Minkowski, Öklid ve Manhattan fonksiyonları örnek olarak verilebilmektedir. Denklem 3.9 grubunda bu üç uzaklık fonksiyonunun matematiksel ifadeleri verilmektedir.

$$d_{minkowski}(x, y) = \left(\sum_{i=1}^N |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (3.9a)$$

$$d_{manhattan}(x, y) = \sum_{i=1}^N |x_i - y_i| \quad (3.9b)$$

$$d_{öklid}(x, y) = \sqrt{\sum_{i=1}^N (x_i - y_i)^2} \quad (3.9c)$$

Denklem 3.9a ‘ da verilen $d_{minkowski}$ N boyutlu uzayda (x, y) koordinatları Minkowski uzaklık fonksiyonunu temsil etmektedir. Minkowski uzaklık fonksiyonunda $p = 1$ olması durumunda Denklem 3.9b’ de verilen Manhattan uzaklık fonksiyonu elde edilmektedir. Minkowski uzaklık fonksiyonunda $p = 2$ olması durumunda Denklem 3.9c’ de verilen Öklid uzaklık fonksiyonu elde edilmektedir. Manhattan ve Öklid uzaklık fonksiyonları, Minkowski uzaklık fonksiyonunun özel bir halidir.

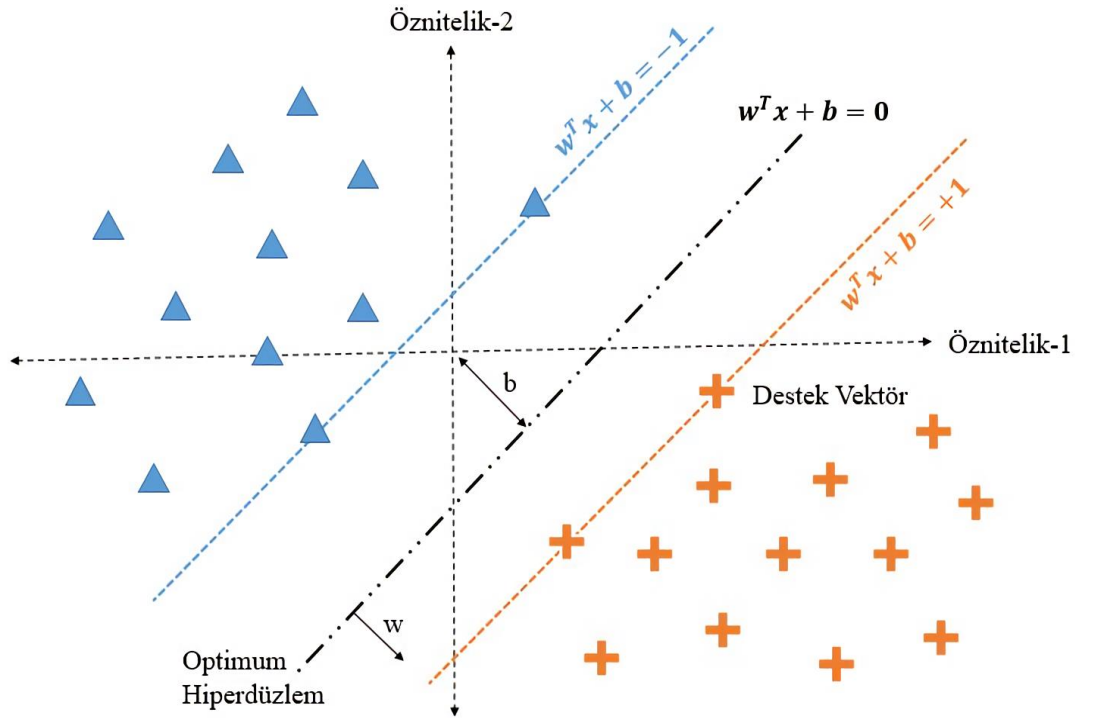
3.5.2. Destek vektör makineleri algoritması

Destek Vektör Makineleri (DVM) Algoritması, doğrusal olan veya doğrusal olmayan iki sınıflı verilerin birbirlerinden ayırt edilebilmesi için en uygun hiperdüzlemi tanımlayan bir sınıflandırıcı algoritmadır. Bu algoritma n boyutlu öznitelik uzayına sahip iki sınıflı bir problemde, sınıfların birbirinden ayırt edilebilmesi için $n - 1$ boyutlu bir hiperdüzlem oluşturmaktadır (Vapnik 2000). İki sınıflı birbirinden ayırt edebilecek optimum hiperdüzlem eşitsizliği Denklem 3.10' da verilmektedir.

$$w^T x_i + b \geq 1, \quad y_i = +1, \quad i = 0, 1, 2, \dots, k - 1 \quad (3.10a)$$

$$w^T x_i + b \leq -1, \quad y_i = -1, \quad i = 0, 1, 2, \dots, k - 1 \quad (3.10b)$$

Denklem grubu 3.10' da verilen x_i ifadesi eğitim verilerini (k : örnek sayısı, n : boyut) temsil etmektedir. y_i ifadesi eğitim verilerinin sınıf etiketlerini (+1, -1) temsil etmektedir. Sınıfları birbirinden ayırt edecek hiperdüzlem için w ağırlık vektörü ve b bias değeri olarak verilmektedir. Şekil 3.5' te doğrusal DVM yapısı verilmektedir.



Şekil 3.5. Doğrusal DVM ve optimum hiperdüzlem yapısı.

DVM algoritması, iki sınıfı birbirinden ayırt edebilmek için optimal olmayan birçok hiperdüzlem çizebilmektedir. Fakat bu algoritma optimal olmayan hiperdüzlemler yerine Denklem 3.11 ile tanımlanan optimal hiperdüzlemi aramaktadır. Optimal hiperdüzlemin çizilebilmesi için Denklem 3.12’ de verilen iki ayrı hiperdüzlemin belirlenmesi gerekmektedir. Bu hiperdüzlemlere “Destek Vektörler” adı verilmektedir.

$$w^T x_i + b = 0 \quad (3.11)$$

$$w^T x_i + b = \pm 1 \quad (3.12)$$

Optimum hiperdüzlem, Denklem 3.12’de verilen destek vektörlerinin optimizasyonu yapılarak minimum değerinin elde edilmesi sonucu elde edilmektedir. İki sınıfı birbirinden optimum hiperdüzlem ile ayırarak sınıflandırma işlemini gerçekleştirecek karar fonksiyonu Denklem 3.13’ te verilmektedir.

$$f(x) = \text{sign} \left(\sum_{i=0}^{k-1} a_i y_i K(x_i, x) + b \right) \quad (3.13)$$

Denklem 3.13’ te verilen K fonksiyonu DVM Algoritmasına ait çekirdek fonksiyonunu (doğrusal, karesel, kübik vb.), x_i eğitim kümesi verilerini, y_i eğitim kümesi etiketlerini ve b bias değerini temsil etmektedir.

3.5.3. Doğrusal ayırım analizi algoritması

Doğrusal Ayırım Analizi (DAA), iki ya da daha fazla sınıflı sınıflandırma problemlerinde verilerin ortalama değerlerinin anlamlı farklılıklar gösterip göstermediğine karar veren bir algoritmadır. Bu yöntemde sınıfların birbirinden ayırt edilmesinde en çok katkıyı sağlayan değişkenler tespit edilmektedir. Katkı payı düşük değişkenlerin bileşkesi alınarak yeni bir değişken üretilmektedir. Yeni değişken ile katkı payı yüksek değişkenler arasındaki farklılık en yüksek seviyededir. DAA Analizi uygulanması basit ve hızlı bir sınıflandırıcı olduğu için BBA uygulamalarında sıklıkla tercih edilmektedir (Bostanov 2003).

DDA Algoritmasında, sınıflar arasındaki farkı belirlemek için ayırıcı fonksiyonlar hesaplanmaktadır. Bu fonksiyonlar sayesinde etiketsiz test verisinin sınıfı tahmin edilmektedir. İki sınıflı bir sınıflandırma problemi için doğrusal ayırıcı fonsiyon Denklem 3.14' te verilmektedir.

$$y(x) = w^T x + b \quad (3.14)$$

Bu denklemde w model parametrelerini ve b sapma değerlerini temsil etmektedir. w ve b değerleri sırasıyla Denklem 3.15 ve Denklem 3.16' da verilmektedir.

$$w = \Sigma^{-1}(\mu_1 - \mu_2) \quad (3.15)$$

$$b = -\frac{w^T (\mu_1 + \mu_2)}{2} \quad (3.16)$$

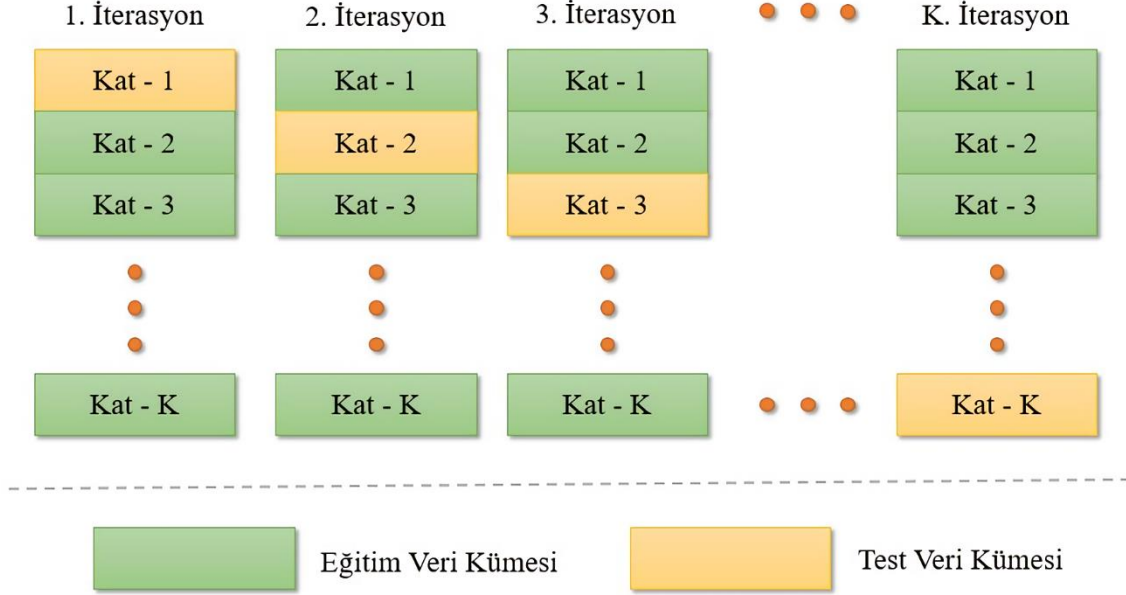
Denklem 3.15 ve Denklem 3.16' da verilen μ_1 ifadesi birinci sınıfın ortalama değer vektörünü ve μ_2 ifadesi ikinci sınıfın ortalama vektörünü temsil etmektedir. Sapma değerinin (b) hesaplanabilmesi için model parametrelerinin elde edilmesi gerekmektedir. Girdi vektörü x için doğrusal ayırıcı fonksiyon $y(x)$ ' in değeri, ayırıcı hiperdüzleme olan uzaklık ile tanımlanmaktadır. $y(x) = 0$ olması karar sınırını ifade etmektedir. $y(x) \geq 0$ olduğu durumda x girdi vektörü birinci sınıf olarak etiketlenmektedir. $y(x) \leq 0$ olduğu durumda x girdi vektörü ikinci sınıf olarak etiketlenmektedir.

3.5.4. Sınıflandırıcı eğitim yöntemi (k-kat çapraz onaylama)

Denetimli öğrenme algoritmalarında kullanılan sınıflandırıcının eğitimi, sınıflandırıcı parametrelerin en uygununun seçimi ile gerçekleştirilmektedir. Sınıflandırıcı eğitimi için literatürde en çok kullanılan yöntem K-Kat Çapraz Onaylama yöntemidir.

K-Kat Çapraz Onaylama yönteminde, eğitim kümesi K adet eşit alt kümeye ayrılmaktadır. K-1 adet veri kümesi sınıflandırıcının eğitimi için ve bir adet veri kümesi test kümesi (validasyon kümesi) olarak kullanılmaktadır. Bu işlem K adet alt kümenin

her birinin en az bir kez test kümesi olarak kullanılması durumuna kadar tekrar edilmektedir. Şekil 3.6 ile K-Kat Çapraz Onaylama yöntemi açıklanmıştır.



Şekil 3.6. K-kat çapraz onaylama yöntemi.

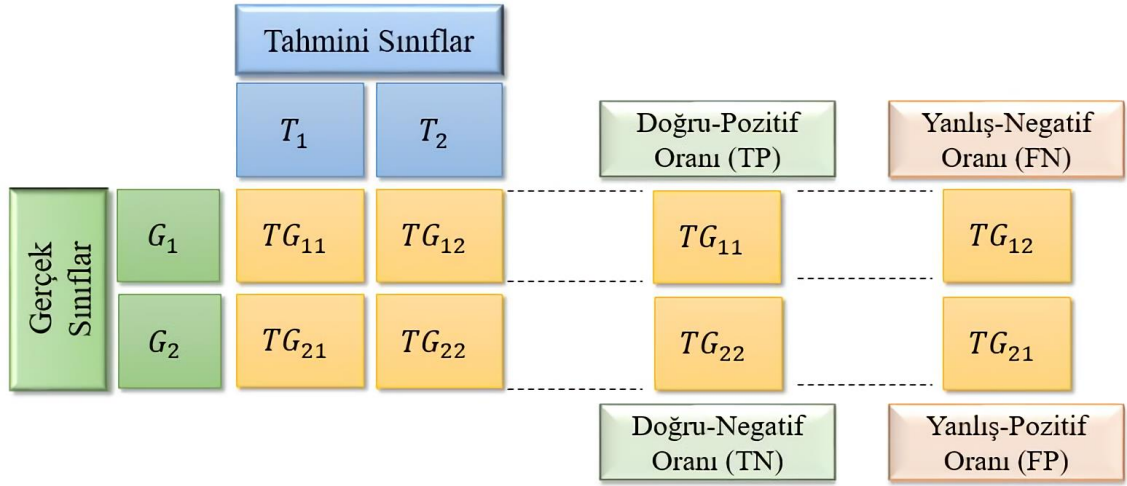
K değerinin seçimi sistem performansını önemli ölçüde etkilemektedir. Literatürde yapılan pek çok çalışmada K değeri 5 (5-Kat Çapraz Doğrulama) veya 10 (10-Kat Çapraz Doğrulama) olarak seçilmektedir (Bradberry ve ark. 2011).

3.5.5. Sınıflandırma başarımlar ölçütleri

BBA uygulamalarında sınıflandırma işlemlerinden sonra, sisteme ait başarımlar sonuçlarının verilmesi için literatürde sıklıkla; toplam sınıflandırma başarımları, seçicilik, duyarlılık, hata matrisi ve ROC (Receiver Operating Characteristic) eğrisi gibi bir çok farklı ölçüt kullanılmaktadır. Bunlardan sınıflandırma başarımları ve hata matrisi çalışmalarda en çok tercih edilen ölçütlerdir. Özellikle çok sınıflı problemlerde, hata matrisi sistem performansını en iyi şekilde ifade edebilmektedir.

Bu tez çalışmada, sınıflandırma işlemi iki sınıflı problem olduğundan sınıflandırma ölçütü olarak toplam sınıflandırma başarımları ve hata matrisi değerleri kullanılmıştır. İki

sınıflı bir problemde, sınıflandırıcı algoritması sonuçlarında dört farklı olası durum meydana gelmektedir. Şekil 3.7’ de bu olası durumlar verilmektedir.



Şekil 3.7. İki sınıflı bir problemde hata matrisi.

Şekil 3.7’de verilen T_1 ve T_2 ifadeleri sınıflandırıcı çıkışından elde edilen tahmini sınıf bilgileridir. G_1 ve G_2 ifadeleri ise verilere ait gerçek sınıf bilgisidir. Hata matrisi içerisinde bu sınıfların kesişmesi ile $TG_{11}, TG_{12}, TG_{21}, TG_{22}$ ile gösterile dört farklı durum oluşmaktadır. Bu kesişim verileri aşağıdaki gibi açıklanmaktadır.

- ✚ TG_{11} : Gerçekte G_1 sınıfına ait olan ve sınıflandırıcının T_1 sınıfına atadığı veri kümesi
- ✚ TG_{12} : Gerçekte G_2 sınıfına ait olan ve sınıflandırıcının T_1 sınıfına atadığı veri kümesi
- ✚ TG_{21} : Gerçekte G_1 sınıfına ait olan ve sınıflandırıcının T_2 sınıfına atadığı veri kümesi
- ✚ TG_{22} : Gerçekte G_2 sınıfına ait olan ve sınıflandırıcının T_2 sınıfına atadığı veri kümesi

İki sınıflı problemlerde TG_{11} ifadesi doğru-pozitif oranı (True-Positive Rate / TP), TG_{12} ifadesi yanlış-negatif oranı (False-Negative Rate / FN), TG_{21} ifadesi yanlış-pozitif oranı (False-Positive Rate / FP) ve TG_{22} ifadesi doğru-negatif oranı (True-Negative Rate / TN) olarak tanımlanmaktadır. Hata matrisinin doğru-pozitif ve doğru-negatif oranları toplamının tüm değerlere onarı sonucu elde edilen toplam sınıflandırma başarısı Denklem 3.17’ de verilmektedir.

$$TSB = \frac{TG_{11} + TG_{22}}{TG_{11} + TG_{12} + TG_{21} + TG_{22}} \quad (3.17)$$

Denklem 3.17' de verilen *TSB* ifadesi toplam sınıflandırma başarısını temsil etmektedir. Tahmin edilen tüm sınıfların, gerçek sınıflar ile aynı olması durumunda ($T_1 = G_1$, $T_2 = G_2$) sınıflandırma işlemi %100 doğruluk ile gerçekleştirilmektedir.

3.6. Derin Öğrenme Tabanlı Sınıflandırma Yöntemleri

20. yüzyılın başında sinir ağları kavramının ortaya çıkması sonucu gelişme sürecine başlayan derin öğrenme, günümüzde teknolojinin ilerlemesi ile hayatımızın her alanında yerini almıştır. Yapay zeka ve makine öğrenmesi kavramlarının bir alt kümesi olan derin öğrenme, literatürde yapılan bir çok çalışmada karmaşık problemlerin yüksek bir doğruluk değeri ile çözümlenmesinde büyük katkı sağlamıştır. Derin öğrenme yöntemleri; sınıflandırma, kestirim, tahmin, ses işleme uygulamaları, doğal dil işleme uygulamaları, örüntü tanıma gibi bir çok farklı alanda önemli rol oynamaktadır (Bengio ve ark. 2013).

Derin öğrenme yöntemleri, insan beyninin çalışma mantığını temel alarak öğrenme işlemini gerçekleştirecek matematiksel modeller oluşturmaktadır. Öğrenme işlemleri denetimli öğrenme ve denetimsiz öğrenme şeklinde yapılabilmektedir.


Denetimli öğrenme algoritmaları, veri seti içerisindeki girdilerden bilinen çıktılara (hedeflere) olan eşleştirmeyi kapsamaktadır. Denetimsiz öğrenme algoritmalarında ise veri seti içerisindeki girdilerden herhangi bir bilinen çıktının (hedefin) yardımı olmadan istenilen işlemin gerçekleştirilmesini amaçlamaktadır. Denetimsiz öğrenme algoritmaları genellikle veriyi görselleştirmek, veriler arası korelasyon ilişkisini anlamak, veriyi sıkıştırmak ve veri içerisindeki gürültüyü azaltmak amacıyla kullanılmaktadır (Hinton ve Sejnowski 1999).

3.6.1. Sinir ağları ve matematiksel modeli

İnsan beyninin eğitilebilme, öğrenebilme, tahmin edebilme, sınıflandırabilme, görselleştirebilme gibi bir çok yeteneği mevcuttur. Bu yeteneklerin bağımsız sistemler tarafından gerçekleştirilebilmesi amacıyla sinir ağları kavramı meydana gelmiştir.

Eđitilebilen, öğrenen ve deęerlendirme iřlemi yapabilen sinir aęları ile insan beyni öğrenme yapısının matematiksel modellenmesi geręekleřtirilmiřtir.

İnsan beyni ierisindeki bir sinir hucresi dentrit, huce ekirdeęi, akson ve sinaps blmlerinden oluřmaktadır. Dendrit, merkezi sinir sisteminden veya dięer sinir hucreslerinden gelen uyarımları huce gvdesine iletmektedir. Huce gvdesinin ierisinde huce ekirdeęi ve organeller bulunmaktadır. Bu bileřenler sayesinde dendritlerden gelen bilgi anlamlandırılmaktadır. Akson ise bu bilginin dięer sinir hucreslerine iletilmesi ile grevlidir. Sinaps baęlantıları ise akson ularının dięer hucreslerdeki dentritlerle olan baęlantısını saęlamaktadır. Yapay sinir aęları ile sinir hucresi ierisindeki bu blmlerin iřlevini gerekleřtirebilecek matematiksel modeller oluřturulmaktadır. řekil 3.8’ de bir sinir hucresine ait matematiksel model verilmektedir.




řekil 3.8. Sinir hucresi matematiksel modeli.

řekil 3.9’ da verilen x_0 , x_1 ve x_2 ifadeleri giriř iřaretlerini, w_0 , w_1 ve w_2 ifadeleri aęırlık deęerlerini temsil etmektedir. Gerek sinir hucresindeki sinaps baęlantıları matematiksel modellemede aęırlıklar ile temsil edilmektedir. Akson ularına gelen giriř iřaretleri aęırlık katsayıları ile arpılarak huce gvdesi ierisinde toplanmaktadır. Elde edilen toplama bias deęerinde eklenmesi ile aktivasyon fonksiyonundan gemekte ve ıkıřa aktarılmaktadır.

3.6.2. Sinir ağlarında ileri ve geri yayılım algoritmaları

Sinir ağlarında öğrenmenin gerçekleşebilmesi için giriş işaretleri, ağırlık katsayıları ve bias değerleri kullanarak ileri ve geri yönde yayılım işlemleri yapılmaktadır. Oluşturulan sinir ağı modelinde; giriş işaretlerinden çıkış değerine doğru yapılan matematiksel işlemler ileri yönde yayılım (forward propagation) olarak adlandırılmaktadır.

Sinir ağının tasarlanması aşamasında, başlangıçta ağırlık değerleri genellikle rastgele seçilmektedir. İleri yönde yayılım işlemi gerçekleştirildikten sonra elde edilen çıkış değeri ve verinin gerçek etiket değeri karşılaştırılmaktadır. Aradaki hata değerinin en aza indirilmesi amacıyla ağırlık ve bias değerlerinin güncellenmesi için yapılan matematiksel işlemler geri yönde yayılım (back propagation) olarak tanımlanmaktadır. Şekil 3.9' da ileri ve geri yönde yayılımın temel yapısı verilmektedir.




Şekil 3.9. İleri ve geri yönde yayılım algoritması temel yapısı.

Şekil 3.9' da verilen x giriş işaretlerini, w ağırlık değerlerini, b bias değerlerini ve L kayıp fonksiyonunu temsil etmektedir. Giriş işaretlerinin ağırlık değerleri ile çarpılıp bias değeri ile toplanması sonucu z fonksiyonu elde edilmektedir. z fonksiyonunun aktivasyon fonksiyonuna girmesi ile çıkış değeri olan \hat{y} ifadesi hesaplanmaktadır. Bu işlemlerin tamamı ileri yönde yayılım olarak tanımlanmaktadır. Geri yönde yayılımın gerçekleştirilebilmesi için \hat{y} ve y (verinin gerçek etiket değeri) değerleri, L kayıp fonksiyonuna tabi tutularak modele ait hata değeri hesaplanmaktadır. Elde edilen hata değerinin en aza indirilmesi amacıyla ağırlık ve bias değerleri güncellenmektedir. Oluşturulan model ileri ve geri yönde yayılım algoritmaları ile öğrenme işlemini tamamlamaktadır.

3.6.3. İki-katmanlı temel sinir ağı yapısı

Temelinde bir gizli katman ve bir çıkış katmanı ile oluşturulan sinir ağı modelleri iki katmanlı sinir ağı yapısı olarak tanımlanmaktadır. Bu yapılar yapay sinir ağlarının en temel modelini oluşturmaktadır. Sinir ağı modellerinde katman sayısı, gizli katman sayısı ve çıkış katmanı sayısının toplamı olarak hesaplanmaktadır. Model içerisinde yer alan giriş katmanı katman sayısına dahil edilmemektedir. Şekil 3.10’ da iki katmanlı temel bir sinir ağı modeli verilmektedir.



Şekil 3.10. İki katmanlı sinir ağı yapısı.

Şekil 3.11’de $x_0, x_1, x_2, \dots, x_i$ ifadeleri giriş işaretlerini ve a_1, a_2, a_3 ifadeleri gizli katmanda bulunan nöronları ifade etmektedir. Gizli katman nöronları üzerinde bulunan (1) ifadesi birinci gizli katmanı temsil etmektedir. Tanımlanan model i adet giriş işaretinden, gizli katman içerisinde bulunan üç adet nöron ve bir çıkış katmanından oluşmaktadır. Modelin ilk katmanında, giriş işaretleri w ağırlık değerleri ile çarpılıp bias değeri ile toplandıktan sonra gizli katmanda bulunan nöronların girişine gelmektedir. $z^{[1]}$ gizli katmandaki nöronların girişine gelen toplam işareti temsil etmek üzere Denklem 3.18 ile tanımlanmaktadır.

$$z^{[1]} = w^{[1]} x + b^{[1]} \quad (3.18)$$

Bu denklemde, $w^{[1]}$ birinci katmana ait ağırlık değerlerini ve $b^{[1]}$ birinci katmana ait bias değerini temsil etmektedir. $z^{[1]}$ ifadesi, model içerisinde gizli katman için tanımlanan f aktivasyon fonksiyonuna tabi tutularak çıkışa $A^{[1]}$ olarak aktarılmaktadır. $A^{[1]}$ değeri Denklem 3.19 ile tanımlanmaktadır.

$$A^{[1]} = f(z^{[1]}) \quad (3.19)$$

Gizli katmanda bulunan nöronların çıkışından gelde edilen $A^{[1]}$ ifadesi, modelin ikinci katmanında bulunan w ağırlık değerleri ile çarpılıp bias değeri ile toplandıktan sonra çıkış katmanının girişine gelmektedir. $z^{[2]}$ çıkış katmanının girişine gelen toplam işareti temsil etmek üzere Denklem 3.20 ile tanımlanmaktadır.

$$z^{[2]} = w^{[2]} A^{[1]} + b^{[2]} \quad (3.20)$$

Bu denklemde, $w^{[2]}$ ikinci katmana ait ağırlık değerlerini ve $b^{[2]}$ ikinci katmana ait bias değerini temsil etmektedir. $z^{[2]}$ ifadesi, model içerisinde çıkış katmanı için tanımlanan f aktivasyon fonksiyonuna tabi tutularak çıkışa $A^{[2]}$ olarak aktarılmaktadır. $A^{[2]}$ değeri Denklem 3.21 ile tanımlanmaktadır.

$$\hat{y} = A^{[2]} = f(z^{[2]}) \quad (3.21)$$

Bu denklemde verilen \hat{y} ifadesi oluşturulan modelin vermiş olduğu çıkış değeri olarak tanımlanmaktadır. Elde edilen çıktı değeri ile etiket değeri (y) değeri model içerisinde tanımlanan kayıp fonksiyonuna tabi tutularak sistemin hata değeri hesaplanmaktadır. J modele ait kayıp fonksiyonunu temsil etmek üzere en küçük kareler yöntemi ile Denklem 3.22' de hesaplanmaktadır.

$$J = \frac{1}{n} \sum_{i=1}^n (\hat{y} - y)^2 \quad (3.22)$$

Kayıp fonksiyonu modele ait hata değerinin bir ifadesidir. Sinir ağı modellerinde amaç kayıp fonksiyonunun en küçük değerde elde edilmesidir. Bu sayede sistem çıkışından elde edilen \hat{y} değerleri y etiket değerleri ile olabildiğince benzerlik gösterecek ve öğrenme işlemi verimli bir şekilde gerçekleştirilecektir.

Denklem 3.22 ile kayıp fonksiyonu hesaplandıktan sonra katmanlarda yer alan ağırlık ve bias değerlerinin güncellenmesi işleminde geri yayılım algoritması kullanılmaktadır. Literatürde yapılan bir çok çalışmada ilgili parametrelerin güncellenmesi için Gradyan İnişi Algoritması (Gradient Descent Algorithm) kullanılmaktadır. Denklem 3.23' de w ağırlık katsayılarının güncellenmesi için Gradyan İnişi Algoritması tanımlanmaktadır.

$$w_{i,j}^{t+1} = w_{i,j}^t - \alpha \left(\frac{dJ}{dw_{i,j}} \right) \quad (3.23)$$

Bu denklemde, α öğrenme katsayısını (öğrenme hızını), $w_{i,j}$ oluşturulan modelde i . katmanda bulunan j . nöronunun ağırlık katsayısını ve t iterasyon sayısını (döngü sayısı) temsil etmektedir.

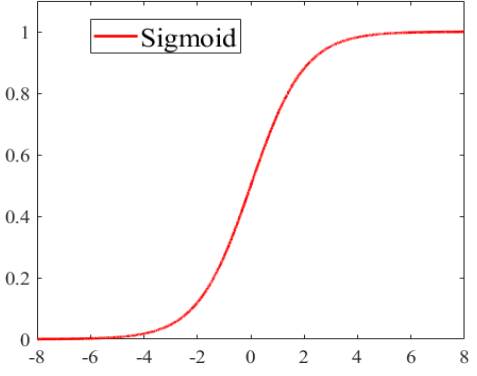
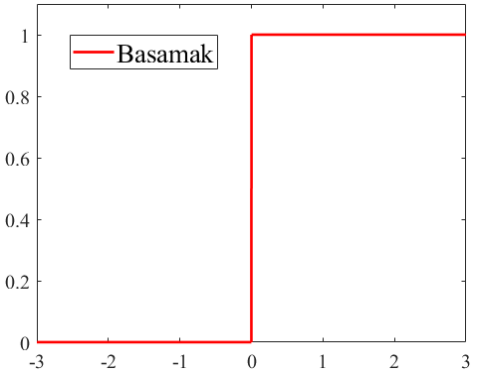
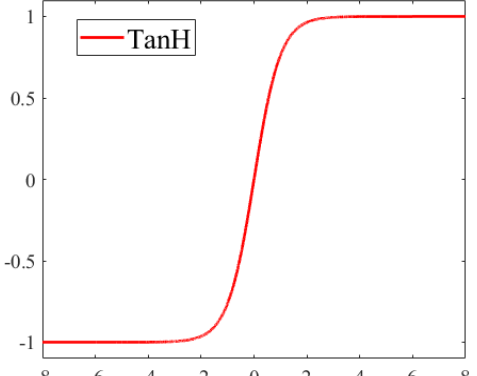
3.6.4. Aktivasyon fonksiyonları

Sinir ağı modellerinde, gerçek sinir ağlarında var olan doğrusal olmayan özelliklerin tanımlanması için aktivasyon fonksiyonları kullanılmaktadır. Temel bir sinir ağı modelinde girdi işaretleri ağırlık değerleri ile çarpılıp bias değeri ile toplanması ardından aktivasyon fonksiyonuna tabi tutulmaktadır. Bu işlem sonucunda elde edilen doğrusal olmayan çıkış, modelin öğrenme sonucu ya da başka bir katmanın girdi işareti olarak kullanılmaktadır.

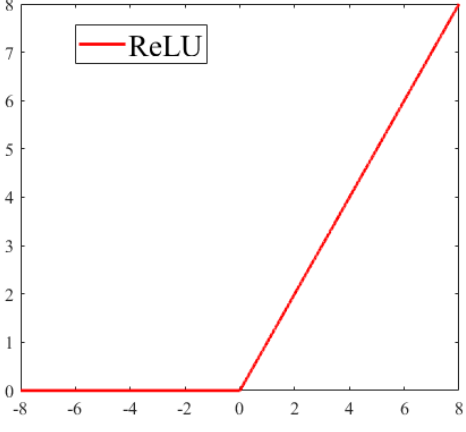
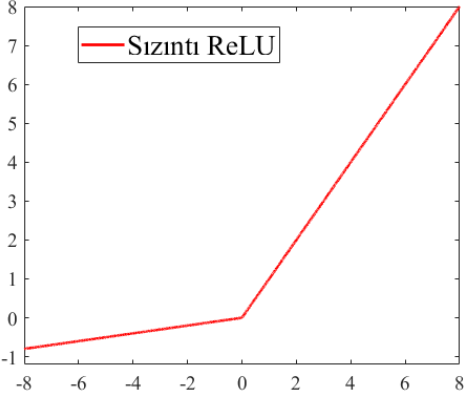
Sinir ağı modellerinde aktivasyon fonksiyonlarının kullanılmaması durumunda çıkış işaretleri doğrusal bir fonksiyon olarak elde edilmektedir. Doğrusal fonksiyonlar modelin öğrenme yeteneğini sınırlandırmaktadır. Sinir ağı modelleri aktivasyon fonksiyonları sayesinde doğrusal olmayan durumlar için öğrenme yetisini genişletmektedir. Bu nedenle aktivasyon fonksiyonu, yapay sinir ağlarında önemli bir rol oynamaktadır.

Literatürde yapılan çalışmalarda en çok tercih edilen aktivasyon fonksiyonları, sigmoid fonksiyonu, basamak fonksiyonu, tanjant hiperbolik fonksiyonu, ReLU (Rectified Linear Unit) fonksiyonu ve sızıntı ReLU fonksiyonu olarak sıralanmaktadır. Çizelge 3.3' te aktivasyon fonksiyonları denklemleri ve grafikleri verilmektedir.

Çizelge 3.3. Aktivasyon fonksiyonları

Adı	Fonksiyon Denklemi	Fonksiyon Grafiği
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	
Basamak	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	
Tanjant Hiperbolik	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	

Çizelge 3.3. Aktivasyon fonksiyonları (devam)

Adı	Fonksiyon Denklemi	Fonksiyon Grafiği
ReLU	$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases}$	
Sızıntılı ReLU	$f(x) = \begin{cases} 0.01x, & x \leq 0 \\ x, & x > 0 \end{cases}$	

Basamak fonksiyonu, öğrenmeye katkı sağlamaması ve türevinin kolay alınabilmesi sebebiyle sinir ağı modellerinde sıklıkla gizli katmanlarda kullanılmaktadır.

Sigmoid fonksiyonu, basamak fonksiyonunun tersine öğrenmeye katkı sağlamaktadır. Bu fonksiyon, girişine uygulanan $[-\infty, \infty]$ aralığındaki değeri çıkışta $[0, 1]$ aralığında iletmektedir.

Tanjant hiperbolik fonksiyonu, yapısal bakımdan sigmoid fonksiyon ile benzerlikler göstermektedir. Sigmoid fonksiyonundan farkı ise girişine uygulanan $[-\infty, \infty]$ aralığındaki değeri çıkışta $[-1, 1]$ aralığında iletmektedir.

ReLU fonksiyonu, girişine uygulanan negatif değerlere karşı sıfır çıktısı üretmektedir. Bu özelliği ile sinir ağının hızlı çalışmasına ve hesaplama işlemlerinin azalmasına katkı

sağlamaktadır. Fakat ReLU fonksiyonunun sıfır çıktığı verdiği bölümlerde türevinde sıfır olması sebebiyle öğrenme işlemini gerçekleştirememektedir.

Sızıntı ReLU fonksiyonu, yapısal bakımdan ReLU fonksiyon ile benzerlikler göstermektedir. ReLU fonksiyonundan farkı ise girişine uygulanan negatif değerleri 0.01'lik bir sızıntı katsayı ile çıkışa aktarmasıdır. Böylece negatif değerlerde de öğrenme işlemini gerçekleştirebilmektedir.

3.6.5. Sinir ağlarında hiperparametrelerin tanımlanması

Küme-Boyutu (Batch Size)

Yapay sinir ağlarının eğitiminde, veri seti içerisindeki tüm deneyler aynı anda model girişine uygulanmamaktadır. Veri seti içerisindeki deneyler, belirlenen bir oran ile bölünerek model girişine sırasıyla girildiği olarak verilmektedir. Böylece model eğitimindeki işlem yükü ve gerekli süre azalmaktadır. Sinir ağının eğitiminde kullanılan her bir veri seti bölümü Küme-Boyutu (Batch Size) olarak adlandırılmaktadır.

Küme boyutu, bir ile eğitim veri seti içerisindeki deney sayısı arasında bir değer alabilmektedir. Küme boyutunun bir (1) olarak seçilmesi durumunda veri kümesi içerisindeki her bir deney, tek tek model girişine aktarılmaktadır. Küme boyutunun eğitim veri seti içerisindeki deney sayısı olarak seçilmesi, bölme işleminin gerçekleşmemesini ve veri seti içerisindeki tüm deneylerin girişe aynı anda aktarılmasını sağlamaktadır. Fakat bu durum küme boyutu mantığına ters düşerek işlem yükünü arttırmaktadır.

Eğitim Döngü Sayısı (Epoch)

Sinir ağının eğitiminde küme boyutunun belirlenmesinin ardından model girişine uygulanan birinci veri seti bölümü ile birlikte tahmin edilen çıkışlar hesaplanmakta ve geri yayılım algoritmasıyla ağırlıklar güncellenmektedir. Bu işlem, her bir veri seti bölümünün model girişine uygulanması tamamlanana kadar tekrarlanmaktadır. Veri seti

içerisindeki tüm kümelerinin, modele aktarılıp eğitim işleminin gerçekleşmesi bir eğitim döngüsü (bir epoch) olarak adlandırılmaktadır.

Sinir ağlarının eğitiminde döngü sayısının seçimi oldukça önemlidir. Geri yayılım algoritması ile ağırlık katsayılarının güncellenmesi işlemi her bir eğitim döngü sayısında hesaplanmaktadır. Oluşturulan modelde döngü sayısının küçük seçilmesi, en uygun ağırlık değerlerinin bulunmadan eğitimin sonlandırılmasına sebep olmaktadır. Bu durum model başarımını düşürmektedir. Eğitim döngü sayısının çok büyük seçildiği modellerde aşırı öğrenme (overfitting) durumu gerçekleşmektedir. Aşırı öğrenme durumunda belli bir döngü sayısında sonra model eğitimini durdurmaktadır. Bu nedenle eğitim döngü sayısı oluşturulan modele göre en uygun şekilde seçilmelidir.

Öğrenme Katsayısı (Learning Rate)

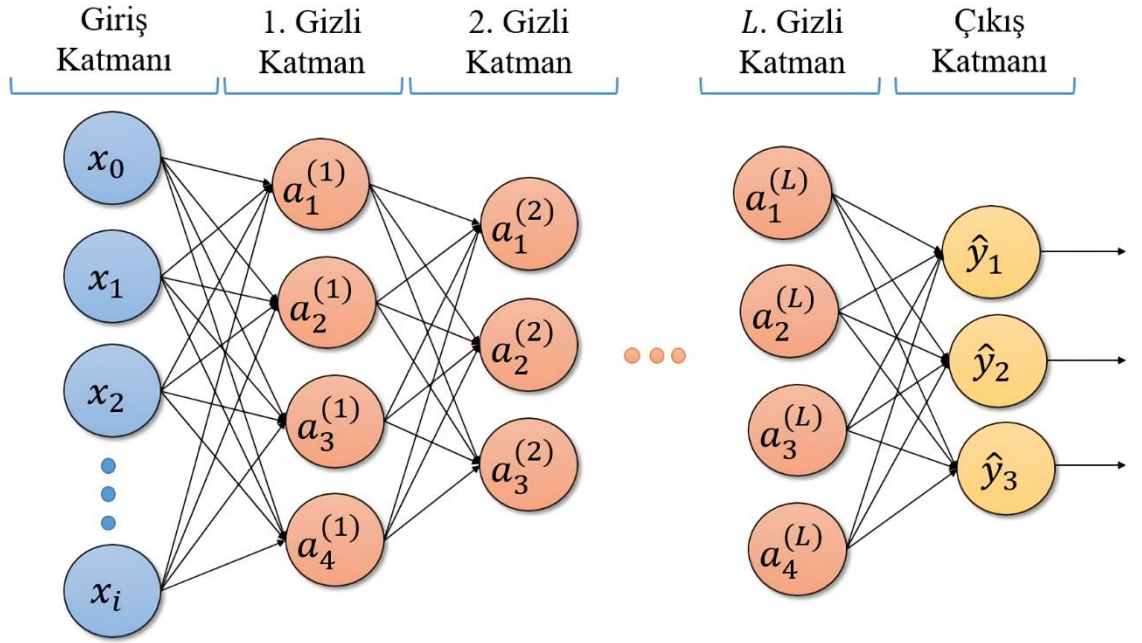
Geriye yayılım algoritması ile ağırlık değerlerinin güncellenmesi işleminde ilk olarak, modelin toplam hata değerinden geriye doğru türev alınması işlemi gerçekleştirilmektedir. Elde edilen sonuç öğrenme katsayısı ile çarpılarak, gerçek ağırlık değerinden çıkarılmakta ve güncel ağırlık değeri hesaplanmaktadır. Bu işlem sırasında belirlenen öğrenme katsayısı sabit bir değer olarak seçilmektedir. Genellikle çok katmanlı sinir ağı modellerinde 1 ile 10^{-6} değerleri arasında tercih edilmektedir.

Optimizasyon Algoritması (Optimizer)

Sinir ağı uygulamalarında öğrenme işlemi temelinde bir optimizasyon problemi olarak tanımlanmaktadır. Doğrusal olmayan fonksiyonların kullanıldığı problemlerin çözümünde en uygun değerlerin elde edilmesi için optimizasyon yöntemleri kullanılmaktadır. Sinir ağı eğitimlerinde genellikle gradyan inişi (gradient descent), adam, adammax, adagrad, adadelta vb. optimizasyon algoritmaları tercih edilmektedir. İlgili algoritmalar, hız ve başarımlar bakımından farklılıklar göstermektedir. Derin öğrenme tabanlı kurulan modellerde genelde varsayılan olarak kullanılan algoritma gradyan inişi algoritmasıdır.

3.6.6. Derin sinir ağı (deep neural network)

Çok Katmanlı Sinir Ağları olarak bilinen Derin Sinir Ağları, birden fazla gizli katman sayısına sahip modeller olarak tanımlanmaktadır. Derin Sinir Ağı modelleri, doğrusal olmayan aktivasyon fonksiyonlarını barındıran bir çok nöronun birbirlerine aşama aşama bağlanması ile oluşturulmaktadır. Derin Sinir Ağı modellerinde katman sayısı, gizli katman sayısı ve çıkış katmanı sayısının toplamı olarak hesaplanmaktadır. Model içerisinde yer alan giriş katmanı katman sayısına dahil edilmemektedir. L modelin katman sayısını temsil etmek üzere çok katmanlı bir sinir ağı “ L -Boyutlu Derin Sinir Ağı” olarak adlandırılmaktadır. Şekil 3.11’de L -Boyutlu Derin Sinir Ağı yapısı verilmektedir.




Şekil 3.11. L -boyutlu derin sinir ağı yapısı

Şekil 3.12’de oluşturulan model giriş katmanı, L adet gizli katman ve çıkış katmanından oluşmaktadır. Model girişine i adet deneyden oluşan veri seti uygulanmıştır. 1. Gizli katmanda dört adet nöron, 2. Gizli katmanda üç nöron, L . Gizli katmanda dört nöron ve çıkış katmanında üç çıkış bulunmaktadır. Varolan problemin yapısına göre oluşturulan modelde boyut sayısı ve gizli katmanlarda bulunan nöron sayısı farklılık gösterebilmektedir.

3.7. Önerilen Yöntemin Akış Diyagramı


Bu tez çalışmasında ilk olarak BCI Competition II veri setine makine öğrenmesi tabanlı klasik sınıflandırıcılar uygulanmış ve sınıflandırma başarıları elde edilmiştir. Şekil 3.12’ de önerilen yöntemin akış diyagramı verilmektedir. Burada “Veri Seti-1” BCI Competition II veri setini temsil etmektedir.



Şekil 3.12. Önerilen yöntem-1 akış diyagramı.

Önerilen yöntem-1’ de ilk olarak veri seti-1 normalizasyon ve alt frekans bandlarına ayırma ön işleme yöntemlerine tabi tutulmaktadır. Sonrasında, farklı öznitelik grupları veri setlerine uygulanarak en yüksek sınıflandırma başarısını gösteren öznitelik grubu, çalışmada kullanılmak üzere seçilmiş ve verilere uygulanmıştır. Öznitelik matrisi içerisindeki yetersiz özniteliklerin çıkarılması için Ardışık İleri Yönde Seçim Algoritması kullanılmıştır. Makine öğrenmesi tabanlı sınıflandırıcılardan k-EYK Algoritması farklı komşuluk değerleri ve mesafe ölçütleri ile, DVM ve DAA Algoritmaları farklı çekirdek fonksiyonları ile sisteme uygulanarak sınıflandırma başarıları elde edilmiştir.

Tez çalışmasının ikinci kısmında, veri seti-1’ e derin öğrenme tabanlı sınıflandırıcılar uygulanmış ve sınıflandırma başarıları elde edilmiştir. Şekil 3.13’ te önerilen yöntemin akış diyagramı verilmektedir.



Şekil 3.13. Önerilen yöntem-2 akış diyagramı.

Önerilen yöntem-1’de olduğu gibi önerilen yöntem-2’ de ön işleme, farklı öznitelik gruplarının veriye uygulanması, en yüksek sınıflandırma başarısına sahip öznitelik grubunun seçimi, Ardışık İleri Yönde Seçim Algoritması ile etkin özniteliklerin seçimi yöntemleri veri seti-1’ e uygulanmıştır.

Derin öğrenme tabanlı sınıflandırıcılardan Derin Sinir Ağları Algoritmasının kullanılabilmesi için ilk olarak oluşturulacak modelde, gizli katman sayısı, katmanlarda bulunacak nöron sayısı, aktivasyon fonksiyonu, öğrenme katsayısı, optimizasyon algoritması, eğitim döngü sayısı, küme boyutu gibi hiperparametrelerin seçimi yapılmıştır. Mimarisi tamamlanan model girişine, öznitelik matrisi uygulanarak sınıflandırma başarıları elde edilmiştir. Model içerisindeki hiperparametrelerden aktivasyon fonksiyonları, gizli katman sayısı, nöron sayısı ve optimizasyon algoritmalarının değiştirilmesi ile sınıflandırma başarısının değişimi analiz edilmiştir.

Tez çalışmasında önerilen iki farklı yöntem ile makine öğrenmesi tabanlı sınıflandırıcılar ve derin öğrenme tabanlı sınıflandırıcılar karşılaştırılmış ve sonuçları analiz edilmiştir.

4. BULGULAR

Bu tez çalışmasında ilk olarak veri kümesi içerisinde bulunan EEG işaretlerine ön işleme yöntemleri (normalizasyon ve alt frekans bandlarına ayırma) uygulanmıştır. Normalize edilmiş ve alt frekans bandlarına ayrılmış olan verilere on farklı öznitelik grubu uygulanmış ve sınıflandırma başarıları analiz edilmiştir. Bu işlem için k-EYK, DVM ve DAA algoritmaları kullanılmıştır. İlgili algoritmalar uygunlanması kolay ve hızlı olmasından dolayı tercih edilmiştir. En yüksek sınıflandırma başarısına sahip öznitelik grubu içerisindeki etkin özniteliklerin tespit edilebilmesi için AİYS algoritması kullanılmıştır. Etkin öznitelik matrisi makine öğrenmesi tabanlı sınıflandırıcılardan k-EYK, SVM, DAA algoritmaları ile derin öğrenme tabanlı sınıflandırıcılardan derin sinir ağları algoritması ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir.

4.1. Ön İşleme Yöntemleri Analizi

BCI Competition II yarışmasına ait III numaralı veri seti $768 \times 3 \times 140$ boyutlu eğitim ve $768 \times 3 \times 140$ boyutlu test verilerinden oluşmaktadır. Burada 140 deney sayısını, 3 kanal sayısını ve 768 veri uzunluğunu temsil etmektedir. Eğitim ve test için ayrılan tüm veriler öncelikle standart sapma normalizasyona tabi tutulmuşlardır. Bu işlem sonucunda veri boyutlarında herhangi bir değişim söz konusu olmamıştır.

Sonrasında normalize edilmiş veriler alt frekans bandlarına (delta, teta, alfa, beta, gama) ayrıştırılmıştır. Bu işlem sonucunda eğitim ve test verilerinin matris boyutu 140×2304 olarak değişmiştir. Eğitim verileri içerisinde bulunan her bir deneyde, veri uzunluğunun tamamı kullanılarak tüm kanallar sırasıyla tasarlanan band geçiren filtreden geçirilmiştir. Bu işlem sonucunda filtrelenmiş sinyalin boyutu bir kanal için 1×768 olarak elde edilmiştir. Deney içerisinde bulunan tüm kanallar için ilgili işlem tekrarlandığında ve elde edilen matrisler yan yana sıralandığında boyutu 1×2304 olan filtrelenmiş sinyal oluşmaktadır. Eğitim ve test verileri içerisindeki tüm deneylere aynı işlemin uygulanması sonucu her bir frekans bandı için toplamda 140×2304 boyutlu filtrelenmiş sinyal çıktısı elde edilmektedir. Çalışmada deney sayısının artırılması için eğitim ve test verileri birleştirilerek 280×2304 boyutlu veri matrisi kullanılmıştır.

4.2. Öznitelik Grubu Seçim Analizi

Normalize edilmiş ve alt frekans bandlarına ayrılmış eğitim ve test verilerine “Öznitelik Çıkarma Yöntemleri” başlığı altında verilen on farklı öznitelik grubu uygulanmış ve sınıflandırma başarıları analiz edilmiştir. Bu işlem için k-EYK, DVM ve DAA algoritmaları kullanılmıştır. Çizelge 4.1’ de k-EYK algoritmasının farklı komşuluk değerlerinde tüm öznitelik grupları için vermiş olduğu toplam sınıflandırma başarıları gösterilmektedir. Sınıflandırma işleminde 10-kat çapraz doğrulama ve Euclidean mesafa ölçütü kullanılmıştır.

Çizelge 4.1. Tüm öznitelik grupları için k-EYK algoritması sınıflandırma başarıları

Öznitelik	k-EYK Algoritması k Değerleri ve Sınıflandırma Başarıları (%)					
	<i>k=1</i>	<i>k=3</i>	<i>k=5</i>	<i>k=7</i>	<i>k=9</i>	<i>k=11</i>
Öznitelik - 1	% 78.8	% 80.7	% 80.1	% 78.4	% 79.3	% 75.7
Öznitelik - 2	% 76.5	% 75.8	% 78.2	% 75.1	% 78.6	% 71.4
Öznitelik - 3	% 80.9	% 79.5	% 81.4	% 80.6	% 82.2	% 82.8
Öznitelik - 4	% 78.2	% 75.4	% 78.7	% 75.3	% 80.4	% 80.1
Öznitelik - 5	% 85.4	% 83.6	% 82.8	% 85.2	% 81.5	% 83.4
Öznitelik - 6	% 83.2	% 80.1	% 79.5	% 83.4	% 78.6	% 80.0
Öznitelik - 7	% 81.3	% 84.2	% 83.1	% 80.5	% 84.0	% 83.5
Öznitelik - 8	% 79.8	% 83.4	% 82.6	% 82.9	% 81.8	% 80.4
Öznitelik - 9	% 84.3	% 85.8	% 84.9	% 86.4	% 85.6	% 84.2
Öznitelik - 10	% 80.1	% 83.6	% 84.3	% 83.0	% 82.3	% 81.5

k-EYK algoritmasında Öznitelik-1 en yüksek % 80.7 ($k=3$), Öznitelik-2 en fazla % 78.6 ($k=9$), Öznitelik-3 en fazla % 82.8 ($k=11$), Öznitelik-4 en fazla % 80.4 ($k=9$), Öznitelik-5 en fazla % 85.4 ($k=1$) için, Öznitelik-6 en fazla % 83.4 ($k=7$), Öznitelik-7 en fazla %

84.2 (k=3), Öznitelik-8 en fazla % 82.9 (k=7), Öznitelik-9 en fazla % 86,4 (k=7) ve Öznitelik-10 en fazla % 84.3 (k=5) sınıflandırma başarısı göstermiştir.

Çizelge 4.2’ de DVM algoritmasının farklı çekirdek fonksiyonlarında tüm öznitelik grupları için vermiş olduğu toplam sınıflandırma başarıları gösterilmektedir. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır.

Çizelge 4.2. Tüm öznitelik grupları için DVM algoritması sınıflandırma başarıları

Öznitelik	DVM Algoritması Çekirdek Fonksiyonları ve Sınıflandırma Başarıları (%)		
	<i>Doğrusal</i>	<i>Karesel</i>	<i>Kübik</i>
<i>Öznitelik - 1</i>	% 80.4	% 82.6	% 78.5
<i>Öznitelik - 2</i>	% 77.4	% 78.8	% 80.2
<i>Öznitelik - 3</i>	% 84.3	% 82.5	% 81.0
<i>Öznitelik - 4</i>	% 80.2	% 77.9	% 78.7
<i>Öznitelik - 5</i>	% 86.7	% 85.8	% 84.6
<i>Öznitelik - 6</i>	% 85.2	% 83.8	% 81.5
<i>Öznitelik - 7</i>	% 83.4	% 85.2	% 81.1
<i>Öznitelik - 8</i>	% 80.8	% 83.5	% 78.6
<i>Öznitelik - 9</i>	% 88.7	% 85.3	% 86.7
<i>Öznitelik - 10</i>	% 85.4	% 85.2	% 86.3

DVM algoritmasında Öznitelik-1 en yüksek % 82.6 (karesel), Öznitelik-2 en fazla % 80.2 (kübik), Öznitelik-3 en fazla % 84.3 (doğrusal), Öznitelik-4 en fazla % 80.2 (doğrusal), Öznitelik-5 en fazla % 86.7 (doğrusal) için, Öznitelik-6 en fazla % 85.2 (doğrusal), Öznitelik-7 en fazla % 85.2 (karesel), Öznitelik-8 en fazla % 83.5 (karesel), Öznitelik-9 en fazla % 88.7 (doğrusal) ve Öznitelik-10 en fazla % 86.3 (kübik) sınıflandırma başarısı göstermiştir.

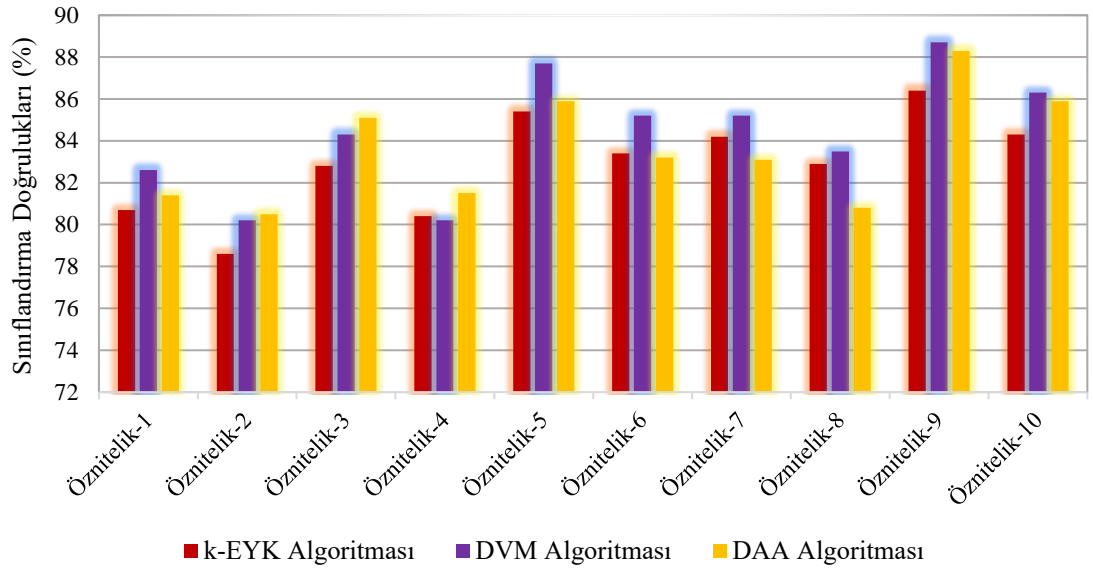
Çizelge 4.3’ te DAA algoritmasının farklı çekirdek fonksiyonlarında tüm öznitelikler için vermiş olduğu sınıflandırma başarıları gösterilmektedir. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır.

Çizelge 4.3. Tüm öznitelik grupları için DAA algoritması sınıflandırma başarıları

Öznitelik	DAA Algoritması Çekirdek Fonksiyonları ve Sınıflandırma Başarıları (%)	
	<i>Doğrusal</i>	<i>Karesel</i>
Öznitelik - 1	% 81.4	% 80.8
Öznitelik - 2	% 80.5	% 78.3
Öznitelik - 3	% 85.1	% 83.5
Öznitelik - 4	% 81.5	% 78.6
Öznitelik - 5	% 85.9	% 84.1
Öznitelik - 6	% 83.2	% 80.8
Öznitelik - 7	% 83.1	% 81.2
Öznitelik - 8	% 80.8	% 79.2
Öznitelik - 9	% 88.3	% 83.5
Öznitelik - 10	% 85.9	% 82.2

DAA algoritmasında Öznitelik-1 en yüksek % 81.4 (doğrusal), Öznitelik-2 en fazla % 80.5 (doğrusal), Öznitelik-3 en fazla % 85.1 (doğrusal), Öznitelik-4 en fazla % 81.5 (doğrusal), Öznitelik-5 en fazla % 85.9 (doğrusal) için, Öznitelik-6 en fazla % 83.2 (doğrusal), Öznitelik-7 en fazla % 83.1 (doğrusal), Öznitelik-8 en fazla % 80.8 (doğrusal), Öznitelik-9 en fazla % 88.3 (doğrusal) ve Öznitelik-10 en fazla % 85.9 (doğrusal) sınıflandırma başarısı göstermiştir.

Farklı öznitelik gruplarının sınıflandırılması işleminde kullanılan üç farklı algoritma için elde edilen en yüksek sınıflandırma doğrulukları Şekil 4.1’ de verilmektedir.



Şekil 4.1. Uygulanan tüm öznitelikler için en yüksek sınıflandırma doğrulukları.

Öznitelik-9 grubu, k-EYK algoritmasında en yüksek % 86,4 DVM algoritmasında % 88,7 ve DAA algoritmasında % 88,3 sınıflandırma başarısı göstererek çalışmada kullanılmak üzere seçilmiştir.

4.3. Ardışık İleri Yönde Seçim Algoritması Analizi

Öznitelik-9 grubu Fourier, Dalgacık ve Hilbert Dönüşümlerini kapsamaktadır. İlgili dönüşümlerin eğitim ve test verilerine uygulanması sonucu tek bir frekans bandı için elde edilen öznitelik matrisleri boyutları Çizelge 4.4' te verilmektedir.

Çizelge 4.4. Öznitelik-9 grubu veri boyutları

Öznitelik-9	Fourier Dönüşümü	Dalgacık Dönüşümü	Hilbert Dönüşümü
Eğitim Verileri Öznitelik Matrisi Boyutu	140 x 9	140 x 12	140 x 12
Test Verileri Öznitelik Matrisi Boyutu	140 x 9	140 x 12	140 x 12
Toplam Öznitelik Matrisi Boyutu	280 x 9	280 x 12	280 x 12

Fourier Dönüşümü alınmış veriden her bir kanal için üç farklı öznitelik (standart sapması, ortalamasının normu ve varyansının normu) çıkarılmış ve bir frekans bandında eğitim-test verileri için boyutu 140×9 olan ilk özellik grubu elde edilmiştir. Dalgacık dönüşümü alınmış veriden her bir kanal için dört farklı öznitelik (ortalaması, standart sapması, basıklık ve çarpıklık katsayısı) çıkarılmış ve bir frekans bandında eğitim-test verileri için boyutu 140×12 olan ikinci özellik grubu elde edilmiştir. Son olarak Hilbert dönüşümü alınmış veriden her bir kanal için dört farklı öznitelik (gerçek kısmı ortalaması ve standart sapması, sanal kısmı ortalaması ve standart sapması) çıkarılmış ve bir frekans bandında eğitim-test verileri için boyutu 140×12 olan üçüncü özellik grubu elde edilmiştir.

Bu işlemler sonucu tüm özellikler ve veriler birleştirilerek öznitelik matrisinin bir frekans bandı için boyutu 280×33 olarak bulunmuştur. Delta, teta, alfa, beta ve gama frekans bandları için aynı işlem tekrarlanmış ve toplam öznitelik matrisi boyutu 280×165 olarak elde edilmiştir.

Öznitelik matrisi içerisinde bulunan 165 özelliğin AİYS algoritması ile farklı kombinasyonları oluşturularak sınıflandırma başarıları analiz edilmiştir. Bu işlem sonucunda sınıfları birbirinden ayırt etmek için yetersiz olan 38 özellik, öznitelik matrisinden çıkarılmıştır. Yeni öznitelik matrisi boyutu ise 280×127 olarak elde edilmiştir.

4.4. k-EYK Algoritması Sınıflandırma Başarısı Analizi

280×127 boyutlu öznitelik matrisi, makine öğrenmesi tabanlı sınıflandırıcılardan ilk olarak k-EYK Algoritması ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. k-EYK Algoritmasında 1-11 değerleri arasında komşu k değerleri ve “Euclidean, City Block, Chebyshev, Minkowski, Mahalanobis, Cosine, Hamming” mesafe ölçütleri kullanılmıştır. Bu sayede farklı komşu değerleri ve farklı mesafe ölçütlerinde sınıflandırma başarıları değerlendirilmiştir. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır. Algoritma sonucunda ayrıca doğru-pozitif oranı (TP) ve doğru-negatif oranı (TN) başarı ölçütleride hesaplanmıştır. Çizelge 4.5’ te k-EYK Algoritması için elde edilen sonuçlar verilmiştir.

Çizelge 4.5. k-EYK algoritması sınıflandırma sonuçları

Mesafe Ölçütleri	k-EYK Algoritması k Değerleri ve Sınıflandırma Başarıları (%)						
	Başarım Ölçütleri	$k=1$	$k=3$	$k=5$	$k=7$	$k=9$	$k=11$
Euclidean	<i>TSB</i>	% 76,4	% 84,6	% 85,4	% 86,4	% 85,7	% 85,4
	<i>TP</i>	% 78,4	% 86,2	% 86,1	% 89,1	% 86,9	% 86,2
	<i>TN</i>	% 74,4	% 83,0	% 84,7	% 83,7	% 84,5	% 84,6
City Block	<i>TSB</i>	% 83,2	% 84,6	% 89,4	% 86,1	% 88,9	% 89,1
	<i>TP</i>	% 84,5	% 85,9	% 90,3	% 88,3	% 89,8	% 90,0
	<i>TN</i>	% 81,9	% 83,3	% 88,5	% 83,9	% 88,0	% 88,2
Chebyshev	<i>TSB</i>	% 74,6	% 74,3	% 72,5	% 75,0	% 72,5	% 72,1
	<i>TP</i>	% 78,1	% 74,8	% 75,3	% 78,2	% 75,3	% 73,6
	<i>TN</i>	% 71,1	% 73,8	% 69,7	% 71,7	% 69,7	% 70,6
Minkowski	<i>TSB</i>	% 78,9	% 85,4	% 80,2	% 82,4	% 83,5	% 85,7
	<i>TP</i>	% 81,8	% 89,5	% 83,7	% 87,6	% 87,8	% 90,3
	<i>TN</i>	% 76,0	% 81,3	% 76,7	% 77,2	% 79,2	% 81,1
Mahalanobis	<i>TSB</i>	% 72,9	% 74,3	% 75,0	% 78,4	% 75,4	% 77,1
	<i>TP</i>	% 75,2	% 77,7	% 78,6	% 81,3	% 77,8	% 80,1
	<i>TN</i>	% 70,6	% 70,9	% 71,4	% 75,5	% 73,0	% 74,1
Cosine	<i>TSB</i>	% 78,6	% 83,2	% 85,7	% 87,5	% 86,1	% 83,6
	<i>TP</i>	% 80,3	% 86,4	% 89,3	% 90,6	% 89,2	% 87,5
	<i>TN</i>	% 76,9	% 80,0	% 82,1	% 84,4	% 83,0	% 79,7
Hamming	<i>TSB</i>	% 72,9	% 74,3	% 75,0	% 71,4	% 75,4	% 77,1
	<i>TP</i>	% 76,3	% 78,1	% 76,5	% 74,6	% 79,3	% 82,1
	<i>TN</i>	% 69,5	% 70,5	% 73,5	% 68,2	% 71,5	% 72,1

k-EYK Algoritması sonucunda; Euclidean mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 86,4 (k=7), City Block mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 89,4 (k=5), Chebyshev mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 75,0 (k=7), Minkowski mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 85,7 (k=11), Mahalanobis mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 78,4 (k=7), Cosine mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 87,5 (k=7) ve Hamming mesafe ölçütünde en yüksek sınıflandırma doğruluğu % 77,1 (k=11) olarak elde edilmiştir. Şekil 4.2’ de City Block mesafe ölçütü kullanılarak elde edilen algoritmadaki en yüksek toplam sınıflandırma doğruluğunun hata matrisi verilmektedir.

		Tahmini Sınıflar		Doğru-Pozitif Oranı (TP)	Yanlış-Negatif Oranı (FN)
		Sınıf-1	Sınıf-2		
Gerçek Sınıflar	Sınıf-1	% 90,3	% 9,7	% 90,3	% 9,7
	Sınıf-2	% 11,5	% 88,5	% 88,5	% 11,5
				Doğru-Negatif Oranı (TN)	Yanlış-Pozitif Oranı (FP)

Şekil 4.2. k-EYK algoritması en yüksek sınıflandırma doğruluğu hata matrisi.

k-EYK Algoritması ile City Blok mesafe ölçütünü kullanarak, % 90,3 doğru-pozitif oranı, % 9,7 yanlış-negatif oranı, % 88,5 doğru-negatif oranı, % 11,5 yanlış-pozitif oranı ve % 89,4 toplam sınıflandırma başarısı elde edilmiştir.

4.5. DVM Algoritması Sınıflandırma Başarısı Analizi

280x127 boyutlu öznitelik matrisi, makine öğrenmesi tabanlı sınıflandırıcılardan ikinci olarak DVM Algoritması ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. DVM Algoritmasında “Doğrusal, Karesel ve Kübik” çekirdek fonksiyonları kullanılmıştır. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır. Çizelge 4.6’ da DVM Algoritması için elde edilen sonuçlar verilmiştir.

Çizelge 4.6. DVM algoritması sınıflandırma sonuçları

Çekirdek Fonksiyonları	Başarım Ölçütleri	DVM Algoritması Sınıflandırma Başarıları (%)
Doğrusal	<i>TSB</i>	% 88,7
	<i>TP</i>	% 90,1
	<i>TN</i>	% 87,3
Karesel	<i>TSB</i>	% 85,3
	<i>TP</i>	% 89,5
	<i>TN</i>	% 81,1
Kübik	<i>TSB</i>	% 86,7
	<i>TP</i>	% 89,7
	<i>TN</i>	% 83,7

DVM Algoritması sonucunda; doğrusal çekirdek fonksiyonu kullanıldığında en yüksek sınıflandırma doğruluğu % 88,7 karesel çekirdek fonksiyonu kullanıldığında en yüksek sınıflandırma doğruluğu % 85,3 ve kübik çekirdek fonksiyonu kullanıldığında en yüksek sınıflandırma doğruluğu % 86,7 olarak elde edilmiştir. Şekil 4.3’ te doğrusal çekirdek fonksiyonu kullanılarak elde edilen algoritmadaki en yüksek toplam sınıflandırma doğruluğunun hata matrisi verilmektedir.

		Tahmini Sınıflar		Doğru-Pozitif Oranı (TP)	Yanlış-Negatif Oranı (FN)
		Sınıf-1	Sınıf-2		
Gerçek Sınıflar	Sınıf-1	% 90,1	% 9,9	% 90,1	% 9,9
	Sınıf-2	% 12,7	% 87,3	% 87,3	% 12,7
				Doğru-Negatif Oranı (TN)	Yanlış-Pozitif Oranı (FP)

Şekil 4.3. DVM algoritması en yüksek sınıflandırma doğruluğu hata matrisi.

DVM Algoritması ile doğrusal çekirdek fonksiyonu kullanarak, % 90,1 doğru-pozitif oranı, % 9,9 yanlış-negatif oranı, % 87,3 doğru-negatif oranı, % 12,7 yanlış-pozitif oranı ve % 88,7 toplam sınıflandırma başarısı elde edilmiştir.

4.6. DAA Algoritması Sınıflandırma Başarısı Analizi

280x127 boyutlu öznitelik matrisi, makine öğrenmesi tabanlı sınıflandırıcılardan üçüncü olarak DAA Algoritması ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. DAA Algoritmasında “Doğrusal ve Karesel” çekirdek fonksiyonları kullanılmıştır. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır. Algoritma sonucunda ayrıca doğru-pozitif oranı (TP) ve doğru-negatif oranı (TN) başarımleride hesaplanmıştır. Çizelge 4.7’ de DAA Algoritması için elde edilen sonuçlar verilmiştir.

Çizelge 4.7. DAA algoritması sınıflandırma sonuçları

Çekirdek Fonksiyonları	Başarım Ölçütleri	DVM Algoritması Sınıflandırma Başarıları (%)
Doğrusal	<i>TSB</i>	% 88,3
	<i>TP</i>	% 89,8
	<i>TN</i>	% 86,8
Karesel	<i>TSB</i>	% 83,5
	<i>TP</i>	% 85,4
	<i>TN</i>	% 81,6

DAA Algoritması sonucunda; doğrusal çekirdek fonksiyonu kullanıldığında en yüksek sınıflandırma doğruluğu % 88,3 ve karesel çekirdek fonksiyonu kullanıldığında en yüksek sınıflandırma doğruluğu % 83,5 olarak elde edilmiştir. Şekil 4.4’ te doğrusal çekirdek fonksiyonu kullanılarak elde edilen algoritmadaki en yüksek toplam sınıflandırma doğruluğunun hata matrisi verilmektedir. Hata matrisi analiz edildiğinde DAA Algoritması ile doğrusal çekirdek fonksiyonu kullanarak, % 89,8 doğru-pozitif oranı, % 10,2 yanlış-negatif oranı, % 86,8 doğru-negatif oranı, % 13,2 yanlış-pozitif oranı ve % 88,3 toplam sınıflandırma başarısı elde edilmiştir.

		Tahmini Sınıflar		Dođru-Pozitif Oranı (TP)	Yanlış-Negatif Oranı (FN)
		Sınıf-1	Sınıf-2		
Gerçek Sınıflar	Sınıf-1	% 89,8	% 10,2	% 89,8	% 10,2
	Sınıf-2	% 13,2	% 86,8	% 86,8	% 13,2
				Dođru-Negatif Oranı (TN)	Yanlış-Pozitif Oranı (FP)

Şekil 4.4. DAA algoritması en yüksek sınıflandırma dođruluđu hata matrisi.

4.7. Derin Sinir Ağları Algoritması Sınıflandırma Başarısı Analizi

4.7.1. İki-katmanlı temel sinir ađı modeli sınıflandırma başarısı analizi

280x127 boyutlu öznitelik matrisi, derin öğrenme tabanlı sınıflandırıcılardan ilk olarak 2-katmanlı temel sinir ađı yapısı ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. 2-katmanlı temel sinir ađı yapısında gizli katmanda bulunan aktivasyon fonksiyonu, gizli katman nöron sayısı ve optimizasyon algoritması deđiştirilerek toplam sınıflandırma başarısı ve standart sapması elde edilmiştir.

Ađ yapısı kurulurken gizli katman aktivasyon fonksiyonu olarak sigmoid – TanH – ReLU, gizli katmanda bulunan nöron sayısı on altı – otuz iki – altmış dört – yüz yirmi sekiz – iki yüz elli altı – beş yüz on iki ve optimizasyon algoritması olarak SGD – Adam – RMSprop – Adadelta kullanılmıştır.

Tüm ađ yapıları kurulurken, çıkış katmanı aktivasyon fonksiyonu olarak sigmoid, kayıp fonksiyonu olarak Binary Crossentropy, eğitim döngü sayısı yüz olarak seçilmiş ve 10-kat çapraz dođrulama yapılmıştır. Çizelge 4.8’ de 2-katmanlı temel sinir ađı modeli için elde edilen sonuçlar verilmiştir.

Çizelge 4.8. 2-katmanlı temel sinir ağı modeli sınıflandırma sonuçları

Gizli Katman Aktivasyon Fonksiyonu	Gizli Katman Nöron Sayısı	Optimizasyon Algoritması	Toplam Sınıflandırma Başarısı (%) [Standart Sapma]
Sigmoid	16	SGD	% 81,43 [\pm 4,57]
		RMSprop	% 87,50 [\pm 4,04]
		Adam	% 87,14 [\pm 3,98]
		Adadelata	% 86,43 [\pm 4,14]
	32	SGD	% 82,86 [\pm 5,02]
		Adam	% 85,71 [\pm 4,25]
		RMSprop	% 86,07 [\pm 4,60]
		Adadelata	% 85,36 [\pm 4,19]
	64	SGD	% 84,29 [\pm 4,46]
		Adam	% 84,64 [\pm 5,45]
		RMSprop	% 85,93 [\pm 4,03]
		Adadelata	% 85,00 [\pm 3,58]
	128	SGD	% 84,29 [\pm 4,11]
		Adam	% 85,05 [\pm 3,69]
		RMSprop	% 85,28 [\pm 4,34]
		Adadelata	% 87,29 [\pm 4,93]
	256	SGD	% 85,06 [\pm 4,02]
		Adam	% 84,64 [\pm 2,97]
		RMSprop	% 84,29 [\pm 3,55]
		Adadelata	% 85,71 [\pm 4,42]
512	SGD	% 86,17 [\pm 5,23]	
	Adam	% 86,36 [\pm 4,53]	
	RMSprop	% 87,14 [\pm 4,93]	
	Adadelata	% 88,07 [\pm 3,79]	
TanH	16	SGD	% 87,14 [\pm 4,41]
		RMSprop	% 86,89 [\pm 4,54]
		Adam	% 85,71 [\pm 4,00]
		Adadelata	% 86,07 [\pm 4,77]
	32	SGD	% 83,29 [\pm 4,93]
		Adam	% 85,64 [\pm 3,99]
		RMSprop	% 86,00 [\pm 4,00]
		Adadelata	% 87,34 [\pm 4,62]

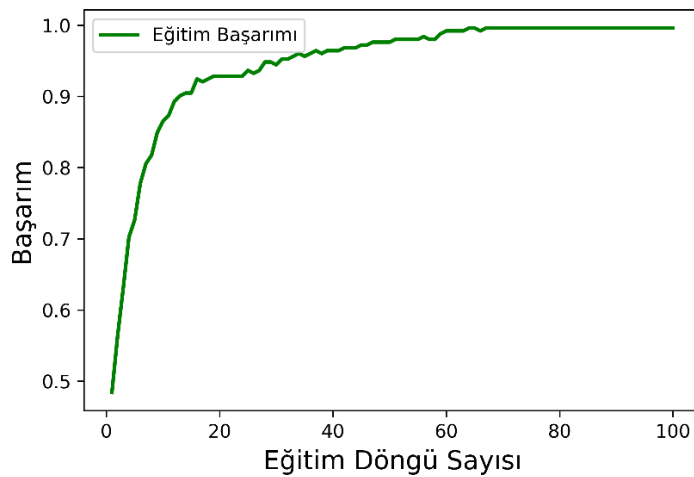
Çizelge 4.8. 2-katmanlı temel sinir ağı modeli sınıflandırma sonuçları (devam)

Gizli Katman Aktivasyon Fonksiyonu	Gizli Katman Nöron Sayısı	Optimizasyon Algoritması	Toplam Sınıflandırma Başarısı (%) [Standart Sapma]
TanH	64	SGD	% 86,43 [± 4,93]
		Adam	% 85,00 [± 4,58]
		RMSprop	% 86,07 [± 4,06]
		Adadelata	% 86,43 [± 4,25]
	128	SGD	% 86,07 [± 2,79]
		Adam	% 84,64 [± 4,40]
		RMSprop	% 85,71 [± 4,58]
		Adadelata	% 85,85 [± 4,20]
	256	SGD	% 86,79 [± 4,91]
		Adam	% 85,71 [± 4,35]
		RMSprop	% 86,07 [± 4,54]
		Adadelata	% 85,36 [± 4,82]
	512	SGD	% 86,07 [± 4,89]
		Adam	% 85,36 [± 4,59]
		RMSprop	% 86,00 [± 4,58]
		Adadelata	% 86,79 [± 4,86]
ReLU	16	SGD	% 84,57 [± 3,78]
		Adam	% 82,07 [± 3,31]
		RMSprop	% 85,07 [± 4,40]
		Adadelata	% 84,64 [± 4,31]
	32	SGD	% 82,50 [± 3,60]
		Adam	% 83,50 [± 4,06]
		RMSprop	% 83,21 [± 2,36]
		Adadelata	% 84,93 [± 3,64]
	64	SGD	% 81,86 [± 4,57]
		Adam	% 81,14 [± 4,84]
		RMSprop	% 84,64 [± 4,99]
		Adadelata	% 81,86 [± 4,49]
	128	SGD	% 86,79 [± 4,07]
		Adam	% 83,21 [± 4,40]
		RMSprop	% 84,29 [± 4,25]
		Adadelata	% 85,36 [± 3,29]

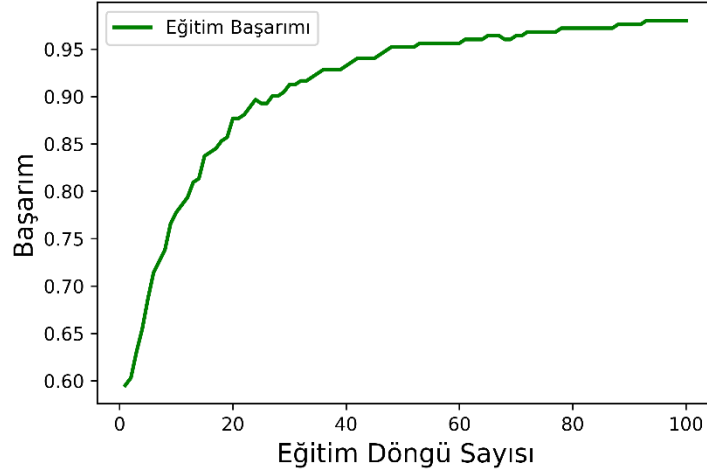
Çizelge 4.8. 2-katmanlı temel sinir ağı modeli sınıflandırma sonuçları (devam)

Gizli Katman Aktivasyon Fonksiyonu	Gizli Katman Nöron Sayısı	Optimizasyon Algoritması	Toplam Sınıflandırma Başarısı (%) [Standart Sapma]
ReLU	256	SGD	% 84,64 [± 4,99]
		Adam	% 85,00 [± 4,58]
		RMSprop	% 83,57 [± 4,66]
		Adadelata	% 84,64 [± 4,31]
	512	SGD	% 85,71 [± 4,02]
		Adam	% 84,29 [± 4,93]
		RMSprop	% 82,86 [± 4,49]
		Adadelata	% 86,85 [± 4,07]

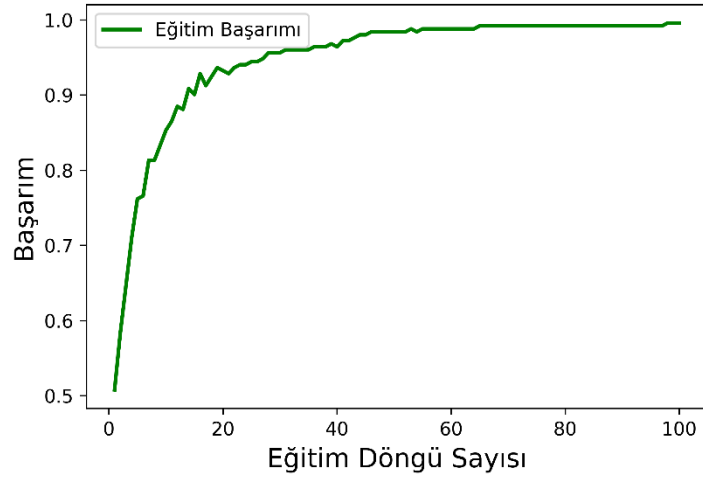
2-katmanlı temel sinir ağı modelinde gizli katman aktivasyon fonksiyonunun sigmoid seçilmesi durumunda (Şekil 4.5) sınıflandırma başarımı en yüksek %88,07 (gizli katman nöron sayısı: 512, optimizasyon algoritması: Adadelata), gizli katman aktivasyon fonksiyonunun TanH seçilmesi durumunda (Şekil 4.6) sınıflandırma başarımı en yüksek %87,34 (gizli katman nöron sayısı: 32, optimizasyon algoritması: Adadelata) ve gizli katman aktivasyon fonksiyonunun ReLU seçilmesi durumunda (Şekil 4.7) sınıflandırma başarımı en yüksek %6,85 (gizli katman nöron sayısı: 512, optimizasyon algoritması: Adadelata) olarak elde edilmiştir. Bu üç başarıım yüzdesinin elde edildiği modellerdeki eğitim başarımı grafiği sırasıyla Şekil 4.5, Şekil 4.6 ve Şekil 4.7’ de verilmektedir.



Şekil 4.5. 2-katmanlı sinir ağı modeli eğitim başarımı grafiği-1.



Şekil 4.6. 2-katmanlı sinir ağı modeli eğitim başarımı grafiği-2.



Şekil 4.7. 2-katmanlı sinir ağı modeli eğitim başarımı grafiği-3.

Şekil 4.5 – 4.7’ de görüldüğü gibi eğitim döngü sayısının artması ile başarı grafiklerinde doğruluk değeri artmakta ve buna bağlı olarak kayıp değeri azalmaktadır. Bunun sebebi eğitim döngü sayısının ilk değerlerinde modele ait parametrelerin (ağırlık değerleri, bias değerleri vb.) rastgele belirlenmiş olmasıdır. Eğitim döngü sayısının artması ile bu değerler güncellenmekte ve en iyi değerlerine yakınsamaktadır. Şekil 4.5’ te kurulan modelde yaklaşık sekseninci eğitim döngü sayısında model parametreleri optimum değere ulaşmıştır. Bu durum Şekil 4.6’ da doksan beşinci ve Şekil 4.7’ de yetmiş beşinci eğitim döngü sayısında gerçekleşmektedir. Ortalama bir eğitim döngü sayısının seçilebilmesi adına oluşturulan modellerde bu değer yüz olarak alınmıştır.

4.7.2. Dört-katmanlı derin sinir ağı modeli sınıflandırma başarısı analizi

280x127 boyutlu öznitelik matrisi, derin öğrenme tabanlı sınıflandırıcılardan ikinci olarak 4-katmanlı derin sinir ağı modeli ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. 4-katmanlı derin sinir ağı yapısında gizli katmanda bulunan aktivasyon fonksiyonları değiştirilerek toplam sınıflandırma başarısı ve standart sapması elde edilmiştir. Ağ yapısı kurulurken gizli katman aktivasyon fonksiyonu olarak sigmoid, TanH ve ReLU fonksiyonları kullanılmıştır.

Tüm ağ yapıları kurulurken, çıkış katmanı aktivasyon fonksiyonu sigmoid, optimizasyon algoritması SGD, kayıp fonksiyonu Binary Crossentropy, eğitim döngü sayısı 400 olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. Çizelge 4.9' da 4-katmanlı derin sinir ağı modeli için elde edilen sonuçlar verilmiştir.

Çizelge 4.9. 4-katmanlı derin sinir ağı modeli sınıflandırma sonuçları

Birinci Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	İkinci Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	Üçüncü Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	Toplam Sınıflandırma Başarısı (%) [Standart Sapma]
Sigmoid [512]	Sigmoid [256]	Sigmoid [64]	% 87,5 [\pm 5,04]
Sigmoid [512]	Sigmoid [256]	ReLU [64]	% 91,07 [\pm 4,40]
Sigmoid [512]	Sigmoid [256]	TanH [64]	% 91,43 [\pm 5,23]
Sigmoid [512]	ReLU [256]	ReLU [64]	% 90,36 [\pm 4,63]
Sigmoid [512]	ReLU [256]	Sigmoid [64]	% 91,07 [\pm 4,79]
Sigmoid [512]	ReLU [256]	TanH [64]	% 89,64 [\pm 4,40]
Sigmoid [512]	TanH [256]	TanH [64]	% 90,00 [\pm 4,23]
Sigmoid [512]	TanH [256]	ReLU [64]	% 89,29 [\pm 4,55]


Çizelge 4.9. 4-katmanlı derin sinir ağı modeli sınıflandırma sonuçları (devam)

Birinci Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	İkinci Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	Üçüncü Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	Toplam Sınıflandırma Başarısı (%) [Standart Sapma]
Sigmoid [512]	TanH [256]	Sigmoid [64]	% 92,50 [± 4,16]
TanH [512]	Sigmoid [256]	Sigmoid [64]	% 90,71 [± 4,02]
TanH [512]	Sigmoid [256]	ReLU [64]	% 90,36 [± 4,19]
TanH [512]	Sigmoid [256]	TanH [64]	% 91,07 [± 4,33]
TanH [512]	ReLU [256]	ReLU [64]	% 90,71 [± 4,57]
TanH [512]	ReLU [256]	Sigmoid [64]	% 90,36 [± 5,53]
TanH [512]	ReLU [256]	TanH [64]	% 91,07 [± 5,54]
TanH [512]	TanH [256]	TanH [64]	% 88,21 [± 4,04]
TanH [512]	TanH [256]	ReLU [64]	% 90,71 [± 4,00]
TanH [512]	TanH [256]	Sigmoid [64]	% 90,36 [± 4,44]
ReLU [512]	Sigmoid [256]	Sigmoid [64]	% 89,93 [± 4,07]
ReLU [512]	Sigmoid [256]	ReLU [64]	% 90,36 [± 4,19]
ReLU [512]	Sigmoid [256]	TanH [64]	% 89,29 [± 4,14]
ReLU [512]	ReLU [256]	ReLU [64]	% 88,21 [± 4,22]
ReLU [512]	ReLU [256]	Sigmoid [64]	% 89,29 [± 4,14]
ReLU [512]	ReLU [256]	TanH [64]	% 88,57 [± 5,05]

Çizelge 4.9. 4-katmanlı derin sinir ağı modeli sınıflandırma sonuçları (devam)

Birinci Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	İkinci Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	Üçüncü Gizli Katman Aktivasyon Fonk. [Nöron Sayısı]	Toplam Sınıflandırma Başarısı (%) [Standart Sapma]
ReLU [512]	TanH [256]	TanH [64]	% 90,29 [\pm 4,93]
ReLU [512]	TanH [256]	ReLU [64]	% 88,21 [\pm 5,48]
ReLU [512]	TanH [256]	Sigmoid [64]	% 89,64[\pm 6,40]

4-katmanlı derin sinir ağı modelinde birinci gizli katman aktivasyon fonksiyonunun sigmoid (nöron sayısı: 512), ikinci gizli katman aktivasyon fonksiyonunun TanH (nöron sayısı: 256) ve üçüncü gizli katman aktivasyon fonksiyonunun sigmoid (nöron sayısı: 64) seçilmesi durumunda sınıflandırma başarımı en yüksek %92,50 [\pm 4,16] olarak elde edilmiştir. Oluşturulan bu modele ait eğitim başarımı grafiği Şekil 4.8 ile verilmektedir.

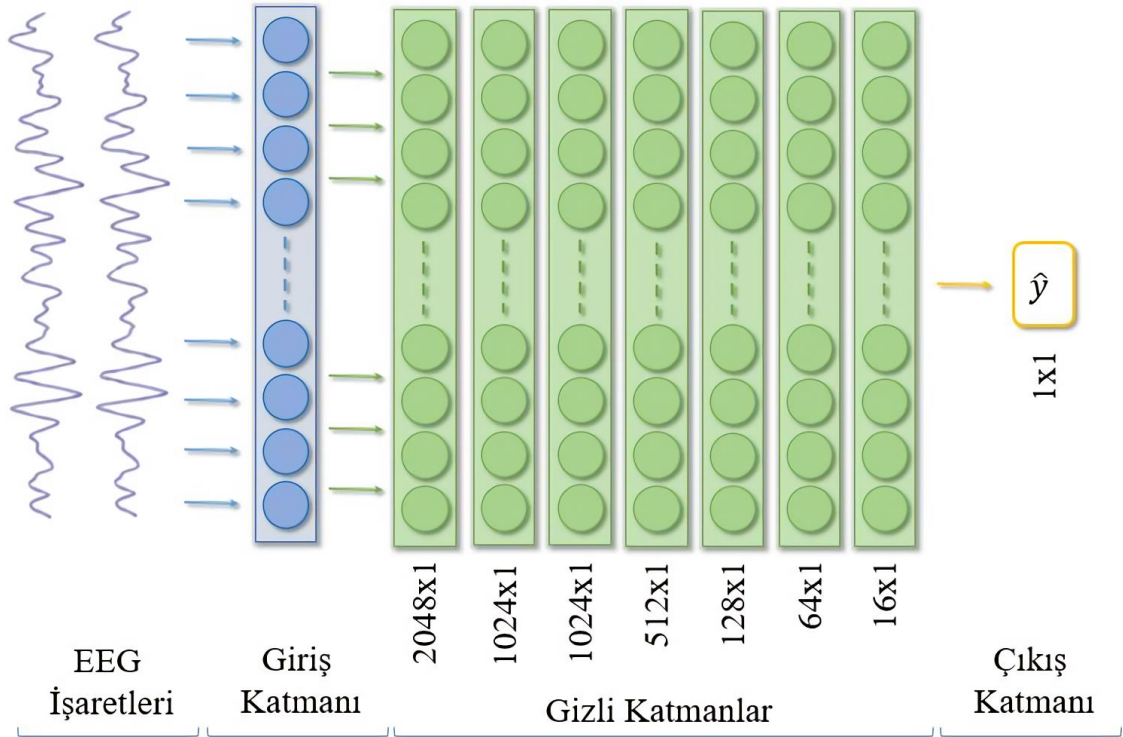


Şekil 4.8. 4-katmanlı derin sinir ağı modeli eğitim başarımı grafiği.

Şekil 4.8' de kurulan modelde yaklaşık üç yüz ellinci eğitim döngü sayısında model parametreleri optimum değere ulaşmıştır. Ortalama bir eğitim döngü sayısının seçilebilmesi adına oluşturulan modellerde eğitim döngü sayısı dört yüz olarak alınmıştır.

4.7.3. Sekiz-katmanlı derin sinir ağı modeli sınıflandırma başarısı analizi

280x127 boyutlu öznitelik matrisi, derin öğrenme tabanlı sınıflandırıcılardan üçüncü olarak 8-katmanlı derin sinir ağı modeli ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. Katman sayısının artması, hiperparametrelerin (gizli katman nöron sayısı, aktivasyon fonksiyonları, optimizasyon algoritması vb.) kombinasyonlarını çoğaltmaktadır. Bu nedenle 8-katmanlı derin modelin oluşturulmasında, en iyi sınıflandırma başarımını sağlayacak farklı hiperparametre değerleri test edilmiştir. İşlem sonucunda en yüksek sınıflandırma doğruluğu % 96,82 ve standart sapması $\pm 2,34$ olarak elde edilmiştir. En yüksek sınıflandırma doğruluğuna sahip model ve hiperparametre değerleri Şekil 4.9' da verilmektedir.



Şekil 4.9. 8-katmanlı derin sinir ağı modeli ve hiperparametre değerleri.

8-katmanlı derin sinir ağı modeli, yedi gizli katman ve bir çıkış katmanından oluşmaktadır. Birinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 2048, ikinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 1024, üçüncü gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 1024, dördüncü gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 512, beşinci gizli katmanda;


aktivasyon fonksiyonu ReLU ve nöron sayısı 128, altıncı gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 64, yedinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 16 olarak seçilmiştir. Çıkış katmanı, iki sınıflı bir problem olduğu için tek nörondan oluşmaktadır.

Model oluşturulurken, çıkış katmanı aktivasyon fonksiyonu sigmoid, optimizasyon algoritması Adadelta, kayıp fonksiyonu Binary Crossentropy, eğitim döngü sayısı 400 olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. 8-katmanlı derin sinir ağı modeline ait detaylar her bir katmandaki parametre sayısı Çizelge 4.10 ile detaylandırılmıştır.

Çizelge 4.10. 8-katmanlı derin sinir ağı modeli detayları

	Katman	Aktivasyon Fonksiyonu	Katman Çıkışı Boyutu	Parametre Sayısı
1	Katman_1 (Dense)	Sigmoid	(None, 2048)	339968
2	Katman_2 (Dense)	ReLU	(None, 1024)	2098176
3	Katman_3 (Dense)	ReLU	(None, 1024)	1049600
4	Katman_4 (Dense)	TanH	(None, 512)	524800
5	Katman_5 (Dense)	ReLU	(None, 128)	65664
6	Katman_6 (Dense)	Sigmoid	(None, 64)	8256
7	Katman_7 (Dense)	Sigmoid	(None, 16)	1040
8	Katman_8 (Dense)	Sigmoid	(None, 1)	17
Toplam Parametre Sayısı				4 087 521

8-katmanlı derin sinir ağı modelinde toplam parametre sayısı 4087521 olarak elde edilmiştir. Modele ait eğitim başarımı grafiği Şekil 4.10 ' da verilmektedir.




Şekil 4.10. 8-katmanlı derin sinir ağı modeli eğitim başarımı grafiği.

Şekil 4.10' da kurulan modelde yaklaşık yüz ellinci eğitim döngü sayısında model parametreleri optimum değere ulaşmıştır. Ortalama bir eğitim döngü sayısının seçilebilmesi adına oluşturulan modellerde eğitim döngü sayısı iki yüz olarak alınmıştır.

4.7.4. On altı-katmanlı derin sinir ağı modeli sınıflandırma başarısı analizi

280x127 boyutlu öznitelik matrisi, derin öğrenme tabanlı sınıflandırıcılardan dördüncü olarak 16-katmanlı derin sinir ağı modeli ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. Katman sayısının artması, hiperparametrelerin (gizli katman nöron sayısı, aktivasyon fonksiyonları, optimizasyon algoritması vb.) kombinasyonlarını çoğaltmaktadır. Bu nedenle 16-katmanlı derin modelin oluşturulmasında, en iyi sınıflandırma başarımını sağlayacak farklı hiperparametre değerleri test edilmiştir.

Sınıflandırma işlemi sonucunda en yüksek sınıflandırma doğruluğu % 94,67 ve standart sapması $\pm 4,08$ olarak elde edilmiştir. En yüksek sınıflandırma doğruluğuna sahip model ve hiperparametre değerleri Şekil 4.11' de verilmektedir.



Şekil 4.11. 16-katmanlı derin sinir ağı modeli ve hiperparametre değerleri.


16-katmanlı derin sinir ağı modeli, on beş gizli katman ve bir çıkış katmanından oluşmaktadır. Birinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 4096, ikinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 2048, üçüncü gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 2048, dördüncü gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 1024, beşinci gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 512, altıncı gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 512, yedinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 256, sekizinci gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 256, dokuzuncu gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 128, onuncu gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 128, on birinci gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 64, on ikinci gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 32, on üçüncü gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 16, on dördüncü gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 8, on beşinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 4 olarak seçilmiştir. Çıkış katmanı, iki sınıflı bir problem olduğu için tek nöronlu oluşmaktadır.

Model oluşturulurken, çıkış katmanı aktivasyon fonksiyonu sigmoid, optimizasyon algoritması RMSprop, kayıp fonksiyonu Binary Crossentropy, eğitim döngü sayısı 400 olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. 16-katmanlı derin sinir ağı modeline ait detaylar her bir katmandaki parametre sayısı Çizelge 4.11 ile detaylandırılmıştır.

Çizelge 4.11. 16-katmanlı derin sinir ağı modeli detayları

	Katman	Aktivasyon Fonksiyonu	Katman Çıkışı Boyutu	Parametre Sayısı
1	Katman_1 (Dense)	Sigmoid	(None, 4096)	679936
2	Katman_2 (Dense)	Sigmoid	(None, 2048)	8390656
3	Katman_3 (Dense)	ReLU	(None, 2048)	4196352
4	Katman_4 (Dense)	TanH	(None, 1024)	2098176
5	Katman_5 (Dense)	TanH	(None, 512)	524800
6	Katman_6 (Dense)	ReLU	(None, 512)	262656
7	Katman_7 (Dense)	ReLU	(None, 256)	131328
8	Katman_8 (Dense)	TanH	(None, 256)	65792
9	Katman_9 (Dense)	Sigmoid	(None, 128)	32896
10	Katman_10 (Dense)	ReLU	(None, 128)	16512
11	Katman_11 (Dense)	Sigmoid	(None, 64)	8256
12	Katman_12 (Dense)	TanH	(None, 32)	2080
13	Katman_13 (Dense)	Sigmoid	(None, 16)	528
14	Katman_14 (Dense)	Sigmoid	(None, 8)	136
15	Katman_15 (Dense)	ReLU	(None, 4)	36
16	Katman_16 (Dense)	Sigmoid	(None, 1)	5
Toplam Parametre Sayısı				16 410 145

16-katmanlı derin sinir ağı modelinde toplam parametre sayısı 16410145 olarak elde edilmiştir. Modele ait eğitim başarımı grafiği Şekil 4.12 'de verilmektedir.



Şekil 4.12. 16-katmanlı derin sinir ağı modeli eğitim başarımı grafiği.

Şekil 4.12' de kurulan modelde yaklaşık yüz yetmişinci eğitim döngü sayısında model parametreleri optimum değere ulaşmıştır. Ortalama bir eğitim döngü sayısının seçilebilmesi adına oluşturulan modellerde eğitim döngü sayısı iki yüz olarak alınmıştır.

5. TARTIŞMA VE SONUÇ

EEG işaretleri, yapısal bakımdan genliği ve frekansı sürekli değişim gösteren karmaşık işaretlerdir. Bu işaretlerin yorumlanarak anlamlandırılabilmesi için matematiksel yöntemler ve analizler gerekmektedir. EEG işaretleri özellikle medikal alanında yapılan teşhislerde ve tedavi süreçlerinin izlenmesinde kullanıldığı gibi günlük hayatı kolaylaştıracak bir çok teknolojik gelişmede de önemli bir rol oynamaktadır. EEG işaretlerinin sıklıkla kullanıldığı alanlardan biri de BBA sistemleridir. BBA sistemleri, EEG işaretlerinin yüksek başarımları ile hızlı bir şekilde yorumlanabilmesini sağlamaktadır. Bu tez çalışmasında BBA sistemleri için bilgisayar ekranına yansıtılan sembolün sağa ve sola hareket ettirilmesinin hayali sırasında kaydedilen açık kaynaklı bir EEG veri seti (BCI Competition II yarışması / III numaralı veri seti) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Yapılan analizler ile iki sınıflı bu problem, başarımları yüksek bir şekilde sınıflandırılmıştır.

Çalışmada ilk olarak, EEG işaretleri ön işleme aşamalarından olan standart sapma normalizasyonu ve alt frekans bandlarına ayırma işlemlerine tabi tutulmuştur. Ön işleme tamamlanan EEG işaretlerinin içerisindeki bilgiyi en iyi şekilde yansıtacak özniteliklerin elde edilebilmesi için on farklı öznitelik grubu seçilmiş ve verilere uygulanmıştır. İlgili öznitelik grupları k-EYK, DVM ve DAA algoritmaları ile sınıflandırılmış ve sınıflandırma başarıları analiz edilmiştir. Bu işlem sonucunda Öznitelik-9 grubu (en yüksek sınıflandırma başarısına sahip grup) k-EYK algoritması ile %86,4 DVM algoritması ile %88,7 ve DAA algoritması ile %88,3 sınıflandırma başarısı göstermiştir. Öznitelik-9 grubu Fourier Dönüşümü, Dalgacık Dönüşümü ve Hilbert Dönüşümü tabanlı özniteliklerden oluşmaktadır.

Öznitelik-9 grubunda bulunan özniteliklerinin EEG işaretlerinin alt frekans bandlarına uygulanması sonucu 280×165 boyutlu öznitelik matrisi elde edilmiştir. Yüksek boyutlu öznitelik matrisleri sistem performansını ve hızını olumsuz yönde etkilediği için bu çalışmada AİYS algoritması ile öznitelik matrisi boyutu azaltılmıştır. Bu algoritma ile ayrıca sınıfların birbirlerinden ayırt edilmesi için yetersiz öznitelikler matristen çıkarılmıştır. AİYS algoritmasının uygulanması sonucu öznitelik matrisi boyutu 280×127 olarak elde edilmiştir.

Bu tez çalışmasında sınıflandırma başarımlarının karşılaştırılabilmesi amacıyla iki farklı yöntem önerilmiştir. Bu yöntemlerde makine öğrenmesi tabanlı sınıflandırıcılar (yöntem-1) ve derin öğrenme tabanlı sınıflandırıcıların (yöntem-2) kullanılması ile sınıflandırma işlemi gerçekleştirilmiştir. 280×127 boyutlu öznitelik matrisi makine öğrenmesi tabanlı sınıflandırıcılardan ilk olarak k-EYK algoritması ile sınıflandırılmıştır. Bu algortmada k komşu değerleri ve mesafe ölçütleri değiştirilerek sınıflandırma başarıları analiz edilmiştir. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır. Algoritma çıktısı sonucunda en yüksek sınıflandırma başarımları $k = 5$ değeri ve City Block mesafe ölçütü kullanılarak %89,4 olarak elde edilmiştir. Bu değer için hata matrisi analiz edildiğinde TP oranı %90,3 ve TN oranı %88,5 olarak elde edilmiştir. Hata matrisinde TP değerinin yüksek çıkması, bir numaralı sınıf olan sembolün sağa gitmesinin hayali sırasında alınan EEG işaretlerinin daha yüksek başarı ile sınıflandırıldığına bir göstergesidir. Bu da deneklerin bu görevi daha kolay gerçekleştirdiğini göstermektedir.

Çalışmada makine öğrenmesi tabanlı sınıflandırıcılardan ikinci olarak DVM algoritması ile sınıflandırma işlemi gerçekleştirilmiştir. Bu algoritmada çekirdek fonksiyonları değiştirilerek sınıflandırma başarıları analiz edilmiştir. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır. Algoritma çıktısı sonucunda en yüksek sınıflandırma başarımları doğrusal çekirdek fonksiyonu kullanılarak %88,7 olarak elde edilmiştir. Bu değer için hata matrisi analiz edildiğinde *TP* oranı %90,1 ve *TN* oranı %87,3 olarak elde edilmiştir. Hata matrisinde *TP* değerinin yüksek çıkması, k-EYK algoritmasında olduğu gibi bir numaralı sınıf olan sembolün sağa gitmesinin hayali sırasında alınan EEG işaretlerinin daha yüksek başarı ile sınıflandırıldığına bir göstergesidir. DVM algoritması k-EYK algoritmasına göre toplam sınıflandırma başarımları ve hata matrisi değerlerinde daha düşük başarımlar göstermiştir.

Çalışmada makine öğrenmesi tabanlı sınıflandırıcılardan son olarak DAA algoritması ile sınıflandırma işlemi gerçekleştirilmiştir. Bu algoritmada, DVM algoritmasında olduğu gibi çekirdek fonksiyonları değiştirilerek sınıflandırma başarımları analiz edilmiştir. Sınıflandırma işleminde 10-kat çapraz doğrulama yapılmıştır. Algoritma çıktısı sonucunda en yüksek sınıflandırma başarımları doğrusal çekirdek fonksiyonu kullanılarak %88,3 olarak elde edilmiştir. Bu değer için hata matrisi analiz edildiğinde *TP* oranı %89,8 ve *TN* oranı %86,8 olarak elde edilmiştir. DAA algoritması k-EYK ve DVM algoritmalarına göre toplam sınıflandırma başarımları ve hata matrisi değerlerinde daha düşük başarımlar göstermiştir.

280x127 boyutlu öznitelik matrisi derin öğrenme tabanlı sınıflandırıcılardan ilk olarak 2-katmanlı temel sinir ağı ile sınıflandırılmıştır. 2-katmanlı temel sinir ağı yapısında gizli katmanda bulunan aktivasyon fonksiyonu, gizli katman nöron sayısı ve optimizasyon algoritması değiştirilerek toplam sınıflandırma başarımları ve standart sapması elde edilmiştir. Ağ yapıları kurulurken, çıkış katmanı aktivasyon fonksiyonu olarak sigmoid, kayıp fonksiyonu olarak Binary Crossentropy, eğitim döngü sayısı yüz olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. Oluşturulan modelde gizli katman aktivasyon fonksiyonununun sigmoid, gizli katman nöron sayısı beş yüz on iki ve optimizasyon algoritması Adaldelta seçilmesi durumunda en yüksek sınıflandırma başarımları %88,07 ve standart sapma $\pm 3,79$ olarak elde edilmiştir.

Derin öğrenme tabanlı sınıflandırıcılardan ikinci olarak 4-katmanlı derin sinir ağı ile sınıflandırılmıştır. 4-katmanlı derin sinir ağı yapısında gizli katmanlarda bulunan aktivasyon fonksiyonları değiştirilerek toplam sınıflandırma başarısı ve standart sapması elde edilmiştir. Ağ yapıları kurulurken, çıkış katmanı aktivasyon fonksiyonu sigmoid, optimizasyon algoritması SGD, kayıp fonksiyonu Binary Crossentropy, eğitim döngü sayısı 400 olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. Oluşturulan modelde birinci gizli katmanda Sigmoid ve beş yüz on iki nöron, ikinci gizli katmanda TanH ve iki yüz elli altı nöron, üçüncü gizli katmanda Sigmoid ve altmış dört nöron seçilmesi durumunda en yüksek sınıflandırma başarısı %92,5 ve standart sapma $\pm 4,16$ olarak elde edilmiştir.

Çalışmada kullanılan derin öğrenme tabanlı sınıflandırıcılardan bir diğeri 8-katmanlı derin sinir ağlarıdır. 8-katmanlı derin sinir ağı yapısında birinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 2048, ikinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 1024, üçüncü gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 1024, dördüncü gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 512, beşinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 128, altıncı gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 64, yedinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 16 olarak seçilmiştir. Model oluşturulurken, çıkış katmanı aktivasyon fonksiyonu sigmoid, optimizasyon algoritması Adadelta, kayıp fonksiyonu Binary Crossentropy, eğitim döngü sayısı 400 olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. İşlem sonucunda en yüksek sınıflandırma doğruluğu %96,82 ve standart sapma $\pm 2,34$ olarak elde edilmiştir.

Derin öğrenme tabanlı sınıflandırıcılardan son olarak 16-katmanlı derin sinir ağı ile sınıflandırılmıştır. 16-katmanlı derin sinir ağı yapısında birinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 4096, ikinci gizli katmanda; aktivasyon fonksiyonu sigmoid ve nöron sayısı 2048, üçüncü gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 2048, dördüncü gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 1024, beşinci gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 512, altıncı gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 512, yedinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 256, sekizinci gizli

katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 256, dokuzuncu gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 128, onuncu gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 128, on birinci gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 64, on ikinci gizli katmanda; aktivasyon fonksiyonu TanH ve nöron sayısı 32, on üçüncü gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 16, on dördüncü gizli katmanda; aktivasyon fonksiyonu Sigmoid ve nöron sayısı 8, on beşinci gizli katmanda; aktivasyon fonksiyonu ReLU ve nöron sayısı 4 olarak seçilmiştir. Model oluşturulurken, çıkış katmanı aktivasyon fonksiyonu sigmoid, optimizasyon algoritması RMSprop, kayıp fonksiyonu Binary Crossentropy, eğitim döngü sayısı 400 olarak seçilmiş ve 10-kat çapraz doğrulama yapılmıştır. İşlem sonucunda en yüksek sınıflandırma doğruluğu %94,67 ve standart sapma $\pm 4,08$ olarak elde edilmiştir. Tez çalışmasında kullanılan tüm sınıflandırma algoritmaları ve sınıflandırma başarımları Çizelge 5.1’ de verilmektedir.

Çizelge 5.1. Sınıflandırma Başarımları Analizi

Sınıflandırma Algoritması	Sınıflandırma Başarısı
k-EYK Algoritması	% 89,4
DVM Algoritması	% 88,7
DAA Algoritması	% 88,3
2-Katmanlı Temel Sinir Ağı Modeli	% 88,07
4-Katmanlı Derin Sinir Ağı Modeli	% 92,5
8-Katmanlı Derin Sinir Ağı Modeli	% 96,82
16-Katmanlı Derin Sinir Ağı Modeli	% 94,67

Çalışma sonucunda makine öğrenmesi tabanlı sınıflandırıcılar, derin öğrenme tabanlı sınıflandırıcı sonuçlarına göre daha düşük başarımlarını göstermiştir. Araştırmalar derin öğrenme tabanlı sınıflandırıcıların, makine öğrenmesi tabanlı sınıflandırıcılara göre birçok problem için yüksek performans gösterdiğini desteklemektedir. Derin öğrenme modellerinde geri yayılım algoritması ile model parametrelerinin en iyilenmesi, modelin güçlenmesi ve yüksek performans göstermesinde büyük önem taşımaktadır. Bu tez çalışması sonucunda elde edilen bulgular ile de ilgili araştırmalar desteklenmektedir.

KAYNAKLAR

- Adeli, H., Zhou, Z., Dadmehr, N. 2003.** Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, 123: 69–87.
- Al Ghayab, H. R., Li, Y., Siuly, S., Abdulla, S. 2018.** Epileptic EEG signal classification using optimum allocation based power spectral density estimation. *IET Signal Processing*, 12(6): 738-747.
- Alickovic, E., Kevric, J., Subasic, A. 2018.** Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction. *Biomedical Signal Processing and Control*, 39: 94-102.
- Amin, H. U., Malik, A. S., Ahmad, R. F., Badruddin, N., Kamel, N., Hussain, M., Chooi, W. 2015.** Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. *Australasian Physical & Engineering Sciences in Medicine*, 38: 139-145.
- Arunkumar, N., Kumar, K. R., Venkataraman, V. 2018.** Entropy features for focal EEG and non focal EEG. *Journal of Computational Science*, 27: 440-444.
- Aydemir, O., Kayikcioglu, T. 2010.** Classifying ECoG based mental tasks using wavelet transform features. 33rd International Conference on Telecommunications and Signal Processing (TSP-2010), 17-20 Ağustos 2010, Viyana, Avusturya.
- Aydemir, O., Kayikcioglu, T. 2011.** comparative performance assessment of classifiers in low-dimensional feature space which are commonly used in BCI applications. *Elektrorevue*, 2(4): 58-63.
- Bengio, Y., LeCun, Y., Hinton, G. 2015.** Deep Learning. *Nature*, 521(7553): 436–444.
- Bhattacharyya, A., Sharma, M., Pachori, R. B., Sircar, P., Acharya, U. R. 2016.** A novel approach for automated detection of focal EEG signals using empirical wavelet transform. *Neural Computing and Applications*, 29: 47-57.
- Birbaumer, N., Elbert, T., Canavan, A. G., Rockstroh, B., 1990.** Slow potentials of the cerebral cortex and behavior. *Physiological Reviews*, 70(1): 1-41.
- Birbaumer, N., 2006.** Breaking the silence: Brain–Computer Interfaces (BCI) for communication and motor control. *Psychophysiology*, 43(6): 517-532.
- Blackwood, D. H., Muir, W. J., 1990.** Cognitive brain potentials and their application. *The British Journal of Psychiatry*, 157(9): 96-101.
- Bostanov, V. 2004.** BCI Competition 2003-Data Sets Ib and IIb: feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram. *Transactions on Biomedical Engineering*, 51(6): 1057-1061.

Bradberry, T. J., Gentili, R. J., Contreras-Vidal, J. L. 2011. Fast attainment of computer cursor control with noninvasively acquired brain signals. *Journal of Neural Engineering*, 8(3): 1-9.

Cao, Z., Chuang, C., King, J., Lin, C. 2019. Multi-channel EEG recording during a sustained-attention driving task. *Scientific Data*, 6: 1-8.

Chai, R., Tran, Y., Naik, G. R., Nguyen, T. N., Ling, S. H., Craig, A., Nguyen, H. T. 2016. Classification of EEG based-mental fatigue using principal component analysis and Bayesian neural network. 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 16-20 Ağustos 2016, Orlando, Florida.

Chapin, J. K., Moxon, K. A., Markowitz, R. S., Nicolelis, M. A. 1999. Real-time control of a robot arm using simultaneous recorded neurons in the motor cortex. *Neuroscience*, 2: 664–670.

Cheong, L. C., Sudirman, R., Hussin, S. S. 2015. Feature extraction of EEG signal using wavelet transform for autism classification. *ARPJ Journal of Engineering and Applied Sciences*, 10: 19-28.

Da Silva, F. L. (2009). EEG:origin and measurement in EEG-fMRI. *Springer*, 8: 19-38.

Demren, E. 2015. Dalgacık dönüşümünün fourier dönüşümü ile karşılaştırılması ve uygulamaları. *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalı, İstanbul.

Der Maaten, L.V., Postma, E. 2009. Dimensionality reduction: a comparative review. Tilburg Centre for Creative Computing, 26 Ekim 2009, Hollanda.

Dhongade, D. V., Rao, T. V. K. H. 2017. Classification of sleep disorders based on EEG signals by using feature extraction techniques with k-nn classifier. 2017 International Conference on Innovations in Green Energy and Healthcare Technologies (IGEHT), 16-18 Mart 2017, Coimbatore, Hindistan.

Ditthaporn, A., Banluesombatkul, N., Ketrat, S., Chuangsuwanich, E., Wilaiprasitporn, T. 2019. Universal joint feature extraction for P300 EEG classification using multi-task autoencoder. *IEEE Access*, 7: 68415-68428.

Donchin, E., Spencer, K. M., Wijesinghe, R. (2000). The mental prosthesis: assessing the speed of a P300-based Brain-Computer Interface. *IEEE Transactions on Rehabilitation Engineering*, 8(2): 174-179.

Doroshenkov, L. G., Konyshchev, V. A., Selishchev, S. V. 2007. Classification of human sleep stages based on EEG processing using hidden markov models. *Biomedical Engineering*, 41(1): 25-28.

Duda, R. O., Hart, P. E. ve Stork, D. G. 2001. Pattern classification. Wiley E-Kitap, Newyork, Amerika Birleşik Devletleri.

- Eklund, A., Andersson, M., Ohlsson, H., Ynnerman, A., Knutsson, H., 2010.** A Brain Computer Interface for communication using real-time fMRI. 2010 International Conference on Pattern Recognition, 23-26 Ağustos 2010, İstanbul, Türkiye.
- Engemann, D. A., Gramfort, A. 2015.** Automated model selection in covariance estimation and spatial whitening of MEG and EEG signals. *NeuroImage*, 108: 328-342.
- Georgopoulos, A. P., Langheim, F. J., Leuthold, A. C., Merkle, A. N., 2005.** Magnetoencephalographic signals predict movement trajectory in space. *Experimental Brain Research*, 167(1): 132-135.
- Guan, S., Zhao, K., Yang, S. 2019.** Motor imagery EEG classification based on decision tree framework and riemannian geometry. *Computational Intelligence and Neuroscience*, 9: 1-13.
- Hayes, M., H. 1998.** Schaum's outline of digital signal processing. McGraw-Hill Inc, Newyork, Amerika Birleşik Devletleri.
- Hinton, G., Sejnowski, T. 1999.** Unsupervised learning: foundations of neural computation. MIT Yayınları, Cambridge, Massachusetts.
- Huang, D., Lin, P., Fei, D. Y., Chen, X., Bai, O., 2009.** Decoding human motor activity from EEG single trials for a discrete two-dimensional cursor control. *Journal of Neural Engineering*, 6(4): 345-352.
- Huijuan, L., Junying, C., Ke, Y., Qun, J., Yu, X., Zhigang, G. 2017.** A hybrid feature selection algorithm for gene expression data classification. *Neurocomputing*, 256: 56-62.
- Hong, J. E., Min, K. C., Seong-Han, K. 2005.** Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. *International Journal of Industrial Ergonomics*, 35(4): 307-320.
- Hou, H., Meng, Q., Zeng, M., Sun, B. 2018.** Improving classification of slow cortical potential signals for BCI systems with polynomial fitting and voting support vector machine. *IEEE Signal Processing Letters*, 25: 283-287.
- Kaynar, O., Arslan, H., Görmez, Y., Işık, Y. E. 2018.** Makine Öğrenmesi ve öznelik seçim yöntemleriyle saldırı tespiti. *Bilişim Teknolojileri Dergisi*, 11(2): 175-185.
- Krauledat, M., Grzeska, K., Sagebaum, M., Blankertz, B., Vidaurre, C., Müller, K. R., Schröder, M., 2009.** Playing pinball with non-invasive BCI. *Advances in Neural Information Processing Systems*, 18: 1641-1648.
- Lebedev, M. A., Nicolelis, M. A. L. 2006.** Brain–Machine Interfaces: past, present and future. *Neuroscience*, 29(9): 536-546.

- Lotte, F., Congedo, M., Lecuyer, A., Lamarche, F., Arnaldi, B., 2007.** A review of classification algorithms for EEG-based Brain–Computer Interfaces. *Journal of Neural Engineering*, R1-R13.
- Ma, L., Minett, J. W., Blu, T., Wang, W. S. 2015.** Resting state EEG-based biometrics for individual identification using convolutional neural networks. 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 25-29 Ağustos 2015, Milan, İtalya.
- Malmivuo, P., Malmivuo, J., Plonsey, R. 1995.** Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields. Oxford University Press, ABD.
- Mehmood, R. M., Lee, H. J. 2015.** Emotion classification of EEG brain signal using SVM and KNN. 2015 IEEE International Conference on Multimedia & Expo Workshops (ICMEW), 29 Haziran-3 Eylül 2015, Turin, İtalya.
- Memar, P., Faradji, F. 2018.** A novel multi-class EEG-based sleep stage classification system. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(1): 84-95.
- Millán, J. D. R., Galán, F., Vanhooydonck, D., Lew, E., Philips, J., Nuttin, M., 2009.** Asynchronous non-invasive brain-actuated control of an intelligent wheelchair. *In Engineering in Medicine and Biology Society*, 16: 3361-3364.
- Mohammed, H., Alomari, E., A., Awada, A., S., Khaled, A. 2014.** Wavelet-based feature extraction analysis of EEG signals associated with imagined fists and feet movements. *Computer and Information Science*, 7: 2-18.
- Muglerab, E., Benschc, M., Haldera, S., Rosenstielc, W., Bogdancd, M., Birbaumerae, N., Kübleraf, A., 2008.** Control of an Internet Browser using the P300 Event-Related Potential. *International Journal of Bioelectromagnetism*, 10(1): 56-63.
- Murugavel, A. S., Ramakrishnan, S. 2015.** Hierarchical multi-class SVM with ELM kernel for epileptic EEG signal classification. *Medical & Biological Engineering & Computing*, 54: 149-161.
- Nasr, M., El-Bahnasy, K., Hamdy, M., Kamal, S. M. 2017.** A novel model based on non invasive methods for prediction of liver fibrosis. 13th International Conference on Electronics and Communication, 28-29 Aralık 2017, Pattaya, Tayland.
- Niedermeyer, E., Da Silva F.H.L. 2005.** Electroencephalography: basic principles, clinical applications and related fields. Lippincott Williams and Wilkins.
- O’Doherty, J. E., Lebedev, M. A., Ifft, P. J., Zhuang, K. Z., Shokur, S., Bleuler, H., Nicolelis, M. A., 2011.** Active tactile exploration using a Brain–Machine–Brain Interface. *Nature*, 479: 7372, 228.

Onay, F. K., Köse, C. 2019. Power spectral density analysis in alfa, beta and gamma frequency bands for classification of motor EEG signals. *27th Signal Processing and Communications Applications Conference (SIU)*, 24-26 Nisan 2019, Sivas, Türkiye.

Oostenveld, R. ve Praamstra, P., 2001. The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical Neurophysiology*, 112(4): 713-719.

Patidar, S., Panigrahi, T. 2017. Detection of epileptic seizure using kraskov entropy applied on tunable-Q wavelet transform of EEG signals. *Biomedical Signal Processing and Control*, 34: 74-80.

Pfurtscheller, G. 1999. EEG event-related desynchronization (ERD) and event-related synchronization (ERS), electroencephalography: basic principals. *Clinical Applications and Related Fields*, 16: 958-967.

Rajaguru, H., Prabhakar, S. K. 2017. Power spectral density and knn based adaboost classifier for epilepsy classification from EEG. *2017 International conference of Electronics, Communication and Aerospace Technology (ICECA)*, 20-22 Nisan 2017, Coimbatore, Hindistan.

Sanei, S., Chambers, J. A. 2013. EEG Signal Processing. John Wiley & Sons.

Schalk, G., Leuthardt, E. C., 2011. Brain-Computer Interfaces using electrocorticographic signals. *IEEE Reviews in Biomedical Engineering*, 4: 140-154.

Schlögl, A., Lugger, K., Pfurtscheller, G. 1997. Using adaptive autoregressive parameters for a Brain-Computer-Interface experiment. *19th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 30 Ekim-2 Kasım 1997, Chicago, ABD.

Schwartz, A. B., Cui, X. T., Weber, D. J., Moran, D. W. 2006. Brain-Controlled Interfaces: movement restoration with neural prosthetics. *Neuron*, 52(1): 205-220.

Semmlow, J. L. 2004. Biosignal and biomedical image processing matlab-based applications, Marcel Dekker, ABD.

Shamwell, J., Lee, H., Kwon, H., Marathe, A. R., Lawhern, V., Nothwang, W. 2016. Single-trial EEG RSVP classification using convolutional neural networks. *Micro and Nano Technology Sensors, Systems and Applications*, 9836: 22-32.

Sharma, M., Pachori, R. B., Acharya, U. R. 2017. A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension. *Pattern Recognition Letters*, 94: 172-179.

Shoorangiz, R., Weddell, S. J., Jones, R. D. 2017. Bayesian multi-subject factor analysis to predict microsleeps from EEG power spectral features. *39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 11-15 Temmuz 2017, Jeju Adası, Güney Kore.

Singh, P., Joshi, S. D., Patney, R. K., Saha, K. 2016. Fourier-based feature extraction for classification of EEG signals using EEG rhythms. *Circuits, Systems and Signal Processing*, 35: 3700-3715.

Siuly, S., Li, Y. 2015. Designing a robust feature extraction method based on optimum allocation and principal component analysis for epileptic EEG signal classification. *Computer Methods and Programs in Biomedicine*, 119(1): 29-42.

Spyrou, L., Sanei, S., Took, C. C. 2007. Estimation and location tracking of the P300 subcomponents from single-trial EEG. In *Acoustics, Speech and Signal Processing, IEEE International Conference (ICASSP 2007)*, 15-20 Nisan 2007, Honolulu, USA.

Suto, J., Oniga, S., Sitar, P. P. 2016. Comparison of wrapper and filter feature selection algorithms on human activity recognition. 6th International Conference on Computers Communications and Control (ICCCC), 10-14 Mayıs 2016, Oradea, Romanya.

Tang, Z. Li, C., Sun, S. 2017. Single-trial EEG classification of motor imagery using deep convolutional neural networks. *Optic*, 130: 11-18.

Teplan, M. 2002. Fundamentals of EEG measurement. *Measurement Science Review*, 2(2): 1-11.

Türk, Ö., Şeker, M., Akpolat, V., Özerdem, M. S. 2017. Classification of mental task EEG records using hjorth parameters. 25th Signal Processing and Communications Applications Conference (SIU), 15-19 Mayıs 2017, Antalya, Türkiye.

URL-1. <http://www.bbc.de/competition/ii/> Erişim Tarihi: 01.03.2020, Konu: BCI Competition Veri Setleri (Veri Seti-III).

Vidal, J. J. 1973. Toward direct Brain-Computer Communication. *Annual review of Biophysics and Bioengineering*, 2(1): 157-180.

Vidyaratne, L. S., Iftekharuddin, K. M. 2017. Real-time epileptic seizure detection using EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11): 2146-2156.

Webster, J. 2009. Medical instrumentation: application and design. John Wiley & Sons, Amerika Birleşik Devletleri.

Webster, J. G., 2014. The physiological measurement handbook. CRC Press, Florida, ABD.

Weiskopf, N., Mathiak, K., Bock S.W., Scharnowski F., Veit R., Grodd W., Goebel, R. ve Birbaumer, N. 2004. Principles of a Brain-Computer Interface (BCI) based on real-time functional magnetic resonance imaging (fMRI), *IEEE Trans Biomedical Engineering*, 51(6): 966-970.

Wang, H., Dragomir, A., Abbasi, N. I., Li, J., Thakor, N. V., Bezerianos, A. 2018. A novel real-time driving fatigue detection system based on wireless dry EEG. *Cognitive Neurodynamics*, 12: 365–376.

Wang, Y., Hong, B., Gao, X., Gao, S. 2007. Implementation of a Brain- Computer Interface based on three states of motor imagery. 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 23-26 Ağustos 2007, Lyon, Fransa.

Williamson, J., Murray-Smith, R., Blankertz, B., Krauledat, M., Müller, K. R. 2009. Designing for uncertain, asymmetric control: interaction design for Brain– Computer Interfaces. *International Journal of Human-Computer Studies*, 67(10): 827-841.

Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., Vaughan, T. M. 2002. Brain–Computer Interfaces for communication and control. *Clinical Neurophysiology*, 113(6): 767-791.

Xiao, R., Ding, L. 2013. Evaluation of EEG features in decoding individual finger movements from one hand. *Computational and Mathematical Methods in Medicine*, 2013: 1-10.

Xu, B., Zhang, L., Song, A., Wu, C., Li, W., Zhang, D., Xu, G., Li, H., Zeng, H. 2019. Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification. *IEEE Access*, 7: 6084-6093.

Yapıcı, Ş., Özsandıkçioğlu, Ü., Atasoy, A. 2018. Boyut azaltma algoritmalarının EEG işaretleri üzerindeki performansının incelenmesi, Sinyal İşleme Ve Uygulamaları-2018 (SİU'2018), 2-5 Mayıs 2018, İzmir, Türkiye.

Zhang, D., Song, H., Xu, R., Zhou, W., Ling, Z., Hong, B. 2013. Toward a minimally invasive Brain–Computer Interface using a single subdural channel: a visual speller study. *Neuroimage*, 71: 30-41.

Zhou, W., Liu, Y., Yuan, Q., Li, X. 2013. Epileptic seizure detection using lacunarity and bayesian linear discriminant analysis in intracranial EEG. *IEEE Transactions on Biomedical Engineering*, 60(12): 3375-3381.

ÖZGEÇMİŞ

Adı Soyadı : Şule BEKİR YAZICI
Doğum Yeri ve Tarihi : Ankara / 27.03.1994
Yabancı Dil : İngilizce

Eğitim Durumu

Lise : Kalaba Lisesi / Ankara
Lisans : Karadeniz Teknik Üniversitesi / Trabzon
Yüksek Lisans : Bursa Uludağ Üniversitesi / Bursa

Çalıştığı Kurum : Bursa Uludağ Üniversitesi
Elektrik-Elektronik Mühendisliği Bölümü

İletişim (e-posta) : suleyapici@uludag.edu.tr

Yayımları

1. **Bekiryazıcı, Ş., Eken, R., Yılmaz, G. 2019.** Titreşim, sıcaklık ve ses faktörlerinin sürücü performansı üzerindeki etkisinin ağırlıklandırılması ve incelenmesi. *Uludağ University Journal of the Faculty of Engineering*, 24(3): 397-412.
2. **Yapıcı, Ş., Özsandıkçioğlu, Ü., Atasoy, A. 2018.** Boyut azaltma algoritmalarının EEG işaretleri üzerindeki performanslarının incelenmesi. 26. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2-5 Mayıs 2018, İzmir, Türkiye.
3. **Yapıcı, Ş., Atasoy, A., Özsandıkçioğlu, Ü. 2018.** Diagnosis of hearth diseases by using cleveland dataset. 7th International Conference on Advanced Technology Sciences, (ICAT 2018), 28 Nisan-1 Mayıs 2018, Antalya, Türkiye.
4. **Özsandıkçioğlu, Ü., Yapıcı, Ş., Atasoy, A. 2018.** Classification of different breath samples utilizing e-nose system. 41st International Conference on Telecommunications and Signal Processing (TSP 2018), 4-6 Eylül 2018, Athena, Yunanistan.
5. **Özsandıkçioğlu, Ü., Atasoy, A., Yapıcı, Ş. 2018.** Hybrid sensor based e-nose for lung cancer diagnosis. 134th IEEE International Symposium on Medical Measurements, 11-13 Haziran 2018, Roma, İtalya.
6. **Özsandıkçioğlu, Ü., Atasoy, A., Yapıcı, Ş. 2018.** E-burun ile akciğer kanserinin tespiti. 26. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2-5 Mayıs 2018, İzmir, Türkiye.
7. **Özsandıkçioğlu, Ü., Atasoy, A., Yapıcı, Ş. 2018.** Detection of lung cancer with QCM sensors based E-Nose. 7th International Conference on Advanced Technology Sciences, (ICAT 2018) 28 Nisan-1 Mayıs 2018, Antalya, Türkiye.