



**DERİN SİNİR AĞLARI İLE EEG VE ALIN EOG
TABANLI DUYGU ANALİZİ**

Hüseyin ÇİZMECİ

**2022
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Caner ÖZCAN**

**DERİN SİNİR AĞLARI İLE EEG VE ALIN EOG TABANLI DUYGU
ANALİZİ**

Hüseyin ÇİZMECİ

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Caner ÖZCAN**

**KARABÜK
Haziran 2022**

Hüseyin ÇİZMECİ tarafından hazırlanan “DERİN SİNİR AĞLARI İLE EEG VE ALIN EOG TABANLI DUYGU ANALİZİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Caner ÖZCAN

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 22/06/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Ergin YILMAZ (BEÜN)

.....

Üye : Dr. Öğr. Üyesi Caner ÖZCAN (KBÜ)

.....

Üye : Doç. Dr. İlker TÜRKER (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Ferhat ATASOY (KBÜ)

.....

Üye : Doç. Dr. Salih GÖRGÜNOĞLU (KÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

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

Hüseyin ÇİZMECİ

ÖZET

Doktora Tezi

DERİN SİNİR AĞLARI İLE EEG VE ALIN EOG TABANLI DUYGU ANALİZİ

Hüseyin ÇİZMECİ

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Caner ÖZCAN

Haziran 2022, 71 sayfa

Duygu tanımada çok kanallı elektroensefalografi (EEG) sinyallerinin kullanımı giderek daha yaygın hale gelmektedir. Ancak yapılan çalışmalarda, EEG sinyallerinin karmaşıklığından dolayı aynı kişiden kaydedilen sinyallerde bile bozulmalar olabildiği görülmüştür. Bu yüzden insan beyninden elde edilen EEG sinyallerinin doğru ve tutarlı bir şekilde analiz edilmesi ve işlenmesi gerekir. Duygu tanımada yüksek doğruluk oranı elde etmek için destek vektör makinesi, yapay sinir ağı, derin inanç ağı ve son zamanlarda sıkça kullanılan evrişimli sinir ağı (CNN) gibi birçok makine öğrenme algoritması kullanılmıştır. Özellikle CNN temelli yaklaşımlar, yüksek doğruluk oranlarına ulaşmaları nedeniyle çok tercih edilmektedir. Ancak bu yaklaşımlar EEG sinyallerinin uzamsal özelliklerini görmezden gelir. Bu nedenle hedef veriler bozulduğunda CNN temelli modellerin sınıflandırma doğruluğu düşer. Başka bir deyişle, geleneksel yöntemler EEG kanallarının komşuluk ilişkisini ve hiyerarşik düzenini tanımlayamaz. Kapsül ağları, EEG sinyallerinin uzamsal özelliklerinin de ağı

öğrettilmesini sağlar. Ancak orijinal kapsül ağında EEG sinyallerinin derin özellikleri tespit edilememektedir. Bu tez çalışmasında, EEG verilerinden uygun kanalların seçilmesini, seçilen kanalların Welch güç spektral yoğunluk tahmini ile özelliklerinin çıkarılmasını ve gelişmiş kapsül ağı tabanlı sınıflandırma algoritmasını içeren bir yöntem sunulmaktadır. Sunulan yöntem üzerine iki ayrı çalışma yapılmıştır. Birinci çalışmada, literatürde bulunan en etkili kanallar tespit edilerek Seed EEG veri setinde pozitif, negatif ve nötr duygular üzerinde yüksek doğruluk oranları (%98.21) elde edilmiştir. Seed EEG veri setinde bulunan elektrookülografi (EOG) verisi, EEG sinyallerindeki göz kırpma artefaktlarını tanımlamak için kullanılmıştır. Aynı zamanda elde edilen sonuçlar CNN, AlexNet, DenseNet, VGG11, LeNet ve ResNet ile karşılaştırılmıştır. Son olarak, önerilen yöntem Dreamer ve Deap veri setleri ile test edilmiştir. İkinci çalışmada ise ABC algoritmasının dört farklı varyasyonu ile Seed EEG veri setindeki en etkili kanallar tespit edilmiş, tespit edilen kanalların Welch güç spektral yoğunluğu tahmini ile özellikleri çıkarılmış ve gelişmiş kapsül ağı tabanlı model ile sınıflandırılmıştır. Çalışma sonucunda Seed EEG veri seti üzerinde %99.83 oranında sınıflandırma doğruluğu elde edilmiştir.

Anahtar Sözcükler : Duygu tanıma, EEG, Özellik çıkarma, Özellik seçme, Derin öğrenme, Kapsül ağları.

Bilim Kodu : 92432

ABSTRACT

Ph. D. Thesis

EEG AND FOREHEAD EOG BASED EMOTION ANALYSIS WITH DEEP NEURAL NETWORKS

Hüseyin ÇİZMECİ

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Assist. Prof. Dr. Caner ÖZCAN

June 2022, 71 pages

The use of multi-channel electroencephalography (EEG) signals in emotion recognition is becoming more common. However, studies have shown that due to the complexity of the EEG signals, even the signals recorded from the same person may be distorted. Therefore, EEG signals obtained from the human brain need to be analyzed and processed accurately and consistently. Many machine learning algorithms such as support vector machine, artificial neural network, deep belief network and convolutional neural network (CNN) have been used in emotion recognition. Especially CNN-based approaches are highly preferred due to their high accuracy. However, these approaches ignore the spatial properties of EEG signals. Therefore, the classification accuracy of CNN-based models decreases when the target data is corrupted. In other words, traditional methods cannot define the neighborhood relationships and hierarchical orders of EEG channels. Capsule networks allow the spatial properties of EEG signals to be taught to the network. However, deep features

of EEG signals cannot be detected in the original capsule network. In this thesis, a method is presented that includes selecting suitable channels from EEG data, extracting the features of selected channels with Welch power spectral density estimation, and an enhanced capsule network-based classification algorithm. Two separate studies were conducted on the presented method. In the first study, the most effective channels in the literature were determined and high accuracy rates (98.21%) were obtained on positive, negative and neutral emotions in the Seed EEG data set. Electrooculography (EOG) data contained in the Seed EEG dataset was used to identify blink artifacts in EEG signals. At the same time, the obtained results were compared with CNN, AlexNet, DenseNet, VGG 11, LeNet and ResNet. Finally, the proposed method has been tested with Dreamer and Deap datasets. In the second study, the most effective channels in the Seed EEG data set were determined with four different variations of the ABC algorithm, the features of the detected channels were extracted by Welch power spectral density estimation and classified with the advanced capsule network-based model. As a result of the study, 99.83% classification accuracy was obtained on the Seed EEG data set.

Key Words : Emotion recognition, EEG, Feature extraction, Feature selection, Deep learning, Capsule networks.

Science Code : 92432

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Caner ÖZCAN'a sonsuz teşekkürlerimi sunarım.

Tez alıőmalarım sırasında yardımlarını esirgemeyen, Bandırma Onyediy Eylül Üniversitesi Mühendislik ve Doęa Bilimleri Fakültesi öğretim üyesi Rafet DURGUT'a teşekkür ederim.

Sevgili aileme manevi hiçbir yardımını esirgemedenden yanımda oldukları için tüm kalbimle teşekkür ederim.

Bu alıőma Karabük Üniversitesi tarafından Bilimsel Araőtırma Projesi olarak FDK-2020-2309 proje numarasıyla desteklenmiőtir.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiv
SİMGELER VE KISALTMALAR DİZİNİ	xv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	6
EEG TABANLI DUYGU ANALİZİ.....	6
2.1. EEG VERİ TABANLARI.....	9
2.1.1. Seed EEG Veri Tabanı.....	9
2.1.2. Dreamer Veri Tabanı	10
2.1.3. Deap Veri Tabanı.....	11
2.2. VERİ ÖN İŞLEME	11
2.2.1. Örnekleme Hızının Düşürülmesi	12
2.2.2. Band Geçiren Filtre.....	12
2.3. KANAL SEÇİMİNDE METASEZGİSEL YÖNTEMLERİN KULLANIMI.....	13
2.3.1. İkili ABC Algoritması (BinABC).....	14
2.3.2. Farklılık Tabanlı ABC Algoritması (DisABC).....	15
2.3.3. Geliştirilmiş İkili ABC Algoritması (iBinABC)	16
2.3.4. Yeni İkili ABC Algoritması (NBABC)	16
2.4. ÖZELLİK SEÇME VE ÇIKARMA.....	17
2.4.1. Welch Güç Spektral Yoğunluğu Tahmini	18

2.4.2. Ayrık Dalgacık Dönüşümü	19
BÖLÜM 3	20
DERİN ÖĞRENME TABANLI EEG DUYGU SINIFLANDIRMA	20
3.1. AKTİVASYON FONKSİYONLARI	20
3.1.1. Sigmoid Fonksiyonu	22
3.1.2. Hiperbolik Tanjant Fonksiyonu	23
3.1.3. ReLU Fonksiyonu	24
3.1.4. Leaky ReLU Fonksiyonu	24
3.1.5. Parametrik ReLU Fonksiyonu	25
3.1.6. Üstel Lineer Birim (ELU) Fonksiyonu	26
3.1.7. SoftMax Fonksiyonu	26
3.1.8. Swish Fonksiyonu	27
3.1.9. GELU Fonksiyonu	27
3.1.10. SELU Fonksiyonu	28
3.2. SINIFLANDIRMA MODELLERİNDE BAŞARI KRİTERLERİ	29
3.3. EVRİŞİMLİ SİNİR AĞLARI (CNN)	30
3.4. KAPSÜL AĞLARI (CapsNet)	32
3.5. DİĞER YÖNTEMLER	36
3.6. GELİŞMİŞ KAPSÜL AĞI (ENHANCED CAPSULE NETWORK)	37
BÖLÜM 4	38
DENEYSEL ÇALIŞMALAR	38
4.1. GELİŞMİŞ KAPSÜL AĞI İLE EEG TABANLI DUYGU TANIMA	38
4.1.1. Ön İşleme	38
4.1.2. Kanal Seçimi	40
4.1.3. Özellik Çıkarma	40
4.1.4. Verilerin Hazırlanması	41
4.1.5. Deneysel Sonuçlar	42
4.2. DERİN EEG SINIFLANDIRMADA METASEZGİSEL YÖNTEMLER	46
4.2.1. Metasezgisel Yöntemler İle Kanal Seçimi	46
4.2.2. Özellik Çıkarma	47

	<u>Sayfa</u>
4.2.3. Verilerin Hazırlanması.....	48
4.2.4. Deneysel Sonuçlar	49
4.2.4.1. BinABC Algoritma Sonuçları.....	49
4.2.4.2. DisABC Algoritma Sonuçları.....	50
4.2.4.3. iBinABC Algoritma Sonuçları.....	52
4.2.4.4. NBABC Algoritma Sonuçları.....	53
4.2.4.5. Ortak Kanallar.....	55
4.2.4.6. Tüm Kanallar	56
BÖLÜM 5	61
SONUÇLAR	61
KAYNAKLAR	63
ÖZGEÇMİŞ	71

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Tek kanal EEG kaydı örneği.....	7
Şekil 2.2. Uluslararası 10-20 sistemi.	8
Şekil 2.3. EEG tabanlı duygu analizi.	9
Şekil 2.4. Deney protokolü.	10
Şekil 2.5. Bir sinyalin örnekleme hızının düşürülmesi.	12
Şekil 2.6. Bant geçiren bir filtre için bant genişliğini (B) gösteren bir şema.....	12
Şekil 2.7. Ayrık Dalgacık Dönüşümü.	19
Şekil 3.1. İkili adım fonksiyonu.....	21
Şekil 3.2. Lineer aktivasyon fonksiyonu.....	21
Şekil 3.3. Sigmoid fonksiyonu.....	22
Şekil 3.4. Hiperbolik tanjant fonksiyonu.	23
Şekil 3.5. ReLU fonksiyonu.....	24
Şekil 3.6. Leaky ReLU fonksiyonu.....	25
Şekil 3.7. Parametrik ReLU fonksiyonu.	25
Şekil 3.8. ELU fonksiyonu.....	26
Şekil 3.9. Swish fonksiyonu.....	27
Şekil 3.10. GELU fonksiyonu.....	28
Şekil 3.11. SELU fonksiyonu.	29
Şekil 3.12. Evrişimli Sinir Ağı.....	30
Şekil 3.13. Bir kapsülün yapısı [76].....	34
Şekil 3.14. Orijinal kapsül ağı mimarisi.	36
Şekil 3.15. Gelişmiş kapsül ağı mimarisi.....	37
Şekil 4.1. Tek bir uygulamadan elde edilen EEG kaydı.	38
Şekil 4.2. Tek kanal (FP_1) EEG kaydı.	39
Şekil 4.3. (62 x 2000) Ham EEG verisinin görselleştirilmiş hali.	39
Şekil 4.4. (8 x 2000) Ham EEG verisinin görselleştirilmiş hali.	40
Şekil 4.5. Ayrık dalgacık dönüşümü ile özellik çıkarma işlemi.	41
Şekil 4.6. Welch güç spektral yoğunluğu tahmini ile özellik çıkarma işlemi.....	41
Şekil 4.7. Modelin doğruluk ve kayıp grafikleri.....	42

Sayfa

Şekil 4.8. Modelin karmaşıklık matrisleri.....	43
Şekil 4.9. Dört algoritma ile seçilen kanallar.....	47
Şekil 4.10. Welch PSD yöntemi ile özellik çıkarma işlemi.....	48
Şekil 4.11. Elde edilen veri setlerinden girdi örnekleri.....	48
Şekil 4.12. BinABC algoritması ile elde edilen doğruluk grafiği.....	49
Şekil 4.13. BinABC algoritması ile elde edilen kayıp grafiği.....	50
Şekil 4.14. DisABC algoritması ile elde edilen doğruluk grafiği.....	51
Şekil 4.15. DisABC algoritması ile elde edilen kayıp grafiği.....	51
Şekil 4.16. iBinABC algoritması ile elde edilen doğruluk grafiği.....	52
Şekil 4.17. iBinABC algoritması ile elde edilen kayıp grafiği.....	52
Şekil 4.18. NBABC algoritması ile elde edilen doğruluk grafiği.....	53
Şekil 4.19. NBABC algoritması ile elde edilen kayıp grafiği.....	54
Şekil 4.20. Ortak kanallar ile elde edilen doğruluk grafiği.....	55
Şekil 4.21. Ortak kanallar ile elde edilen kayıp grafiği.....	55
Şekil 4.22. Tüm kanallar ile elde edilen doğruluk grafiği.....	56
Şekil 4.23. Tüm kanallar ile elde edilen kayıp grafiği.....	57
Şekil 4.24. Doğruluk ve kayıp değerleri.....	58

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1. Beyin dalgaları [41].	6
Çizelge 2.2. Deneyleerde kullanılan film klipleri [9].	10
Çizelge 2.3. Dreamer veri formatı [51].	11
Çizelge 2.4. Deap veri formatı [51].	11
Çizelge 2.5. NBABC Algoritması.	17
Çizelge 3.1. Karmaşıklık matrisi.	29
Çizelge 3.2. Dinamik yönlendirme algoritması [76].	35
Çizelge 4.1. Modelin sınıflandırma metrikleri.	44
Çizelge 4.2. Elde edilen doğruluk ve verimlilik sonuçları.	45
Çizelge 4.3. Dreamer ve Deap veri setinden elde edilen doğruluk değerleri.	45
Çizelge 4.4. Kanal seçim sonuçları.	47
Çizelge 4.5. BinABC algoritması ile elde edilen doğruluk ve kayıp değerleri.	50
Çizelge 4.6. BinABC algoritması ile elde edilen sınıflandırma metrikleri.	50
Çizelge 4.7. DisABC algoritması ile elde edilen doğruluk ve kayıp değerleri.	51
Çizelge 4.8. DisABC algoritması ile elde edilen sınıflandırma metrikleri.	52
Çizelge 4.9. iBinABC algoritması ile elde edilen doğruluk ve kayıp değerleri.	53
Çizelge 4.10. iBinABC algoritması ile elde edilen sınıflandırma metrikleri.	53
Çizelge 4.11. NBABC algoritması ile elde edilen doğruluk ve kayıp değerleri.	54
Çizelge 4.12. NBABC algoritması ile elde edilen sınıflandırma metrikleri.	54
Çizelge 4.13. Ortak kanallar ile elde edilen doğruluk ve kayıp değerleri.	56
Çizelge 4.14. Ortak kanallar ile elde edilen sınıflandırma metrikleri.	56
Çizelge 4.15. Tüm kanallar ile elde edilen doğruluk ve kayıp değerleri.	57
Çizelge 4.16. Tüm kanallar ile elde edilen sınıflandırma metrikleri.	57
Çizelge 4.17. Sınıflandırma sonuçları.	59
Çizelge 4.18. Sınıflandırma metrikleri.	60

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

- f_0 : Merkez frekans
 f_a : Yüksek kesme frekansı
 f_b : Düşük kesme frekansı
 x_i : Mevcut çözüm
 x_n : Komşu çözüm
 v_i : Aday çözüm
 N : Popülasyondaki birey sayısı
 \emptyset : Ölçekleme faktörü için kullanılan katsayı
 t : Yenileme sayısı
 W_{ij} : Ağırlık matrisi
 u_i : Alt seviye kapsülün çıkış vektörü
 c_{ij} : Dinamik yönlendirme ile belirlenen bağlantı katsayıları
 Ω_L : Kapsül kümesi
 M : Poz matrisi
 a : Aktivasyon olasılığı
 Δx : x ekseninde değişim
 Δy : y ekseninde değişim

KISALTMALAR

EEG : Elektroensefalografi

EMG : Elektromiyogram

EKG : Elektrokardiyogram

SNR : Signal to Noise Ratio (Sinyal – Gürültü Oranı)

PSD : Power Spectral Density (Güç Spektral Yoğunluğu)

DWT : Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)

SVM : Support Vector Machine (Destek Vektör Makinesi)

MLP : Multi Layer Perceptron (Çok Katmanlı Algılayıcılar)

LDA : Linear Discriminant Analysis (Lineer Diskriminant Analizi)

ASR : Artifact Subspace Reconstruction (Artefakt Altuzay Yeniden Yapılandırması)

ABC : Artificial Bee Colony (Yapay Arı Kolonisi)

MSE : Mean Squared Error (Ortalama Hata Karesi)

GD : Gradient Descent (Gradyan İniş)

CNN : Convolutional Neural Network (Evrışimli Sinir Ağları)

BÖLÜM 1

GİRİŞ

Duygu, bir nesnenin veya durumun bilinçli veya bilinçsiz algılanmasıyla tetiklenen psikofizyolojik bir süreçtir ve genellikle ruh hali, mizaç, kişilik, eğilim ve motivasyonla ilişkilendirilir. Duygu araştırması, bilgisayar bilimi, psikoloji, sinirbilimi ve bilişsel bilimlerle ilgili araştırmaları kapsayan disiplinler arası bir alandır. Çağdaş insan - bilgisayar etkileşimi sistemlerinin çoğu bu bilgiyi yorumlamada yetersizdir ve duygusal zekâ eksikliğinden muzdariptir. Başka bir deyişle bu sistemler, insanın duygusal hallerini yeterince tanımlayamadığı için uygun eylemlere karar vermekte genelde kullanılamazlar. Bu alanda yapılan çalışmaların amacı, insan-bilgisayar etkileşimi sırasında ortaya çıkan duygusal ipuçlarını tespit ederek ve duygusal tepkileri sentezleyerek aradaki bu boşluğu doldurmaktır.

Duygu tanımada elektroensefalografi (EEG) [1], elektromiyogram (EMG) [2], elektrokardiyogram (EKG) [3] ve cilt direnci [4] gibi birçok fizyolojik sinyal kullanılmakta ve diğer geleneksel yöntemlerle karşılaştırıldığında olumlu sonuçlar elde edilmektedir. Özellikle EEG sinyallerine dayanan yöntemler, yüz ifadesi ve jest gibi diğer dış görünüm ipuçlarına kıyasla yüksek doğruluk ve objektif değerlendirme nedeniyle daha güvenilirdir [5]. Çeşitli psikofizyoloji çalışmaları, insan duyguları ve EEG sinyalleri arasındaki korelasyonları göstermiştir [6-8]. Ancak EEG sinyalleri düşük sinyal-gürültü oranına (SNR) sahiptir ve çoğu zaman gürültü ile karıştırılmaktadır [9]. Bununla birlikte daha zor olan kısım, görüntü veya konuşma sinyallerinden farklı olarak, EEG sinyallerinin oldukça karmaşık yapıda olmasıdır [10]. Bu yüzden EEG sinyallerinin analizi oldukça zordur. EEG sinyallerinin sade ve tutarlı bir şekilde temsil edilmesi için özellik çıkarma/seçme teknikleri uygulanır [11]. Ancak kritik kanalların ve frekans bantlarının nasıl seçileceği ve seçilen elektrot havuzlarının nasıl değerlendirileceği henüz tam olarak araştırılmamıştır.

Son zamanlarda arařtırmacılar, EEG tabanlı duygu tanıma için farklı yöntemlerle kritik frekans bantlarını ve kanallarını bulmaya odaklandılar [9]. Li vd. [12], duygu tanımda en uygun bandı seçmek için bir frekans bandı arama yöntemi önermiştir ve aldıkları sonuçlar, Gama bandının (yaklaşık 30-100 Hz.), EEG tabanlı duygu sınıflandırma için uygun olduğunu göstermiştir. Duygu tanıma için kullanılan elektrotların konumlarının ne olacağı ise başka bir tartışma konusudur. Bos [13], F3 ve F4' ün duygusal değeriği tespit etmek için en uygun elektrot konumları olduğunu göstermiştir. Valenzi vd. [14], sekiz elektrotlu (AF3, AF4, F3, F4, F7, F8, T7 ve T8) bir havuz elde etmiş ve bu sekiz elektrot ile ortalama %87.5 oranında sınıflandırma doğruluğuna ulaşmıştır. Özellik çıkarma/seçme işlemlerinde metasezgisel yöntemlerin kullanımı da oldukça yaygındır [15]. Makul sürelerde ulařtıkları başarı ve kolay uygulanabilirlik sayesinde bir çok problemde olduğu gibi özellik çıkarma/seçme probleminde de sıklıkla kullanılmaktadır. Özellik alt kümeleri oluşturulduktan sonra, bu kümeler arasındaki bilgi paylaşımında metasezgiseller oldukça başarılıdır [16]. Özellik seçim problemi metasezgiseller ile çözülmeye çalışıldığında ikili (0,1) problem olarak ele alınmaktadır. Tabu arama [17], benzetimli tavlama [18], kayıttan-kayıta seyahat [19], genetik algoritma [20], parçacık sürü optimizasyonu [21], karınca kolonisi optimizasyonu [22], diferansiyel evrim [23] ve yapay arı kolonisi [24] gibi bir çok algoritmaların bu problem üzerinde çalışabilen versiyonları önerilmektedir. Bununla birlikte elde edilen siyallerin sade ve tutarlı bir şekilde temsil edilebilmesi için Güç Spektral Yoğunluğu, Ayrık Dalgacık Dönüşümü ve Diferansiyel Entropi gibi yöntemler de kullanılmaktadır.

Duan vd. [25], duygusal durumlar ile ilişkili özellikleri temsil etmek için diferansiyel entropi (DE) adlı bir EEG özelliği önermiş ve önerisini diferansiyel asimetri, rasyonel asimetri ve enerji spektrumu ile karşılařtırmıştır. Deney sonunda sırasıyla %84.22, %80.96, %83.28 ve %76.56 oranlarında sınıflandırma doğruluğuna elde etmiştir. Islam vd. [26], Ayrık Dalgacık Dönüşümü' nü kullanarak DEAP veritabanındaki EEG sinyallerini, K-En Yakın Komşu (KNN) algoritmasında eğiterek 62.3 ± 1.1 doğruluk değeriine ulaşmışlardır. Lai vd. [27], Bruxizm uyku sendromunun analizi için EEG sinyallerinden elde edilen EMG1-EMG2 ve ECG1-ECG2 kanallarının, güç spektral yoğunluğu ile özelliklerini çıkarmış ve karar ağacı ile sınıflandırmasını yapmışlardır.

Yaptıkları çalışma ile tıbbi uygulamalar için yüksek oranda sınıflandırma doğruluğu elde etmişlerdir.

Derin öğrenmenin ortaya çıkması, sinyal ve bilgi işlemede büyük bir etki meydana getirmiştir [28]. Yapay sinir ağlarında derinlik, katman sayısını ifade ederken genişlik, katmandaki düğüm sayısını ifade eder [29]. Derin otomatik kodlayıcılar [30], evrişimsel sinir ağı [31, 32] ve derin inanç ağı [33] gibi birçok derin öğrenme algoritması önerilmiştir.

Zheng vd. [9], yaptıkları çalışmada, 15 denekten elde edilen 62 kanal EEG veri seti ile 4, 6, 9 ve 12 kanallı profiller oluşturarak diferansiyel entropi ile özelliklerini çıkardılar. Elde ettikleri bu verileri derin inanç ağı temelli model ile eğiterek %86.65 doğruluk oranına ulaştılar. Li vd. [34], EEG sinyalleri ile insan duygularını tanımak için EEG sinyallerinin uzamsal özelliklerini, frekans alanını ve zamansal özelliklerini birleştirdiler ve bunları iki boyutlu bir görüntü ile eşleştirdiler. Bu sayede EEG sinyalleri ile duygu varyasyonunu temsil etmek için EEG çok boyutlu özellik görüntüsü (EEG MFI) dizisi oluşturdu. Daha sonra CNN, uzun kısa süreli bellek (LSTM) ve tekrarlayan sinir ağı (RNN) mimarileri ile hibrid bir derin sinir ağı inşa ettiler ve DEAP veri seti ile ortalama % 75,21 oranında bir sınıflandırma doğruluğuna ulaştılar. Li vd. [35], önerdikleri sınıflandırma yönteminde ilk olarak rastgele orman algoritması ile EEG sinyallerinin önemli elektrotları tespit edilmiş, ardından elde edilen verilerin dalgacık dönüşümü yöntemi ile özellikleri çıkarılmış ve son olarak evrişimli sinir ağı kullanılarak sınıflandırma işlemi yapılmıştır. Deney sonunda %93.22 oranında bir sınıflandırma doğruluğu elde edilmiştir. Wang vd. [36], motor görüntü için kaydedilen elektroensefalografi verilerini aldıktan sonra 4 ve 48 Hz arasındaki üç elektrottan ortalama güç spektral yoğunluğunu hesapladılar. Elde ettikleri veriler ile evrişimli sinir ağını eğiterek, diğer yöntemlere (LDA, SVM ve MLP) kıyasla (%85 üzeri doğruluk oranı ile) daha iyi bir sınıflandırma performansı sağlayabildiğini gösterdiler. Ozcan vd. [37], önerdikleri Welch güç spektral yoğunluğu tahminine ve evrişimsel sinir ağına dayanan yöntem ile, SEED EEG veri seti üzerinde yüksek oranda sınıflandırma doğruluğu elde etmişlerdir. Geleneksel yöntemlerin yetersiz kaldığı alanların tespit edilmesi ve sınıflandırma doğruluğunun artırılabilmesi için bir çok yeni derin öğrenme modeli geliştirilmekte ve uygulanmaktadır.

Ha vd. [38]' ye göre, evrişimsel sinir ağlarının dezavantajı, hedef veriler bozulduğunda ağın sınıflandırma performansının düşmesidir. Bu sorunun üstesinden gelmek için, EEG sinyallerinin çeşitli özelliklerini dolaylı olarak öğrenen ve böylece geleneksel CNN yaklaşımlarından daha sağlam ve güvenilir performans elde eden kapsül ağlarını (CapsNet) önerdiler. Bu çalışmada, iki sınıflı motor görüntü sinyalleri kısa süreli fourier dönüşümü (KSFD) kullanılarak zaman frekanslı görüntülere dönüştürüldü. Elde edilen görüntüler kapsül ağlarını eğitmek ve test etmek için kullanıldı. İşlem sonunda % 77 oranında bir sınıflandırma doğruluğu elde edildi. Chao vd. [39]' ye göre, geleneksel yöntemler, duygu durumları ile ilgili bilgiler içeren EEG sinyallerinin mekansal özelliklerini görmezden gelmektedir. Bu nedenle, çok bantlı bir özellik matrisine (Multiband Feature Matrix - MFM) ve bir kapsül ağa dayanan derin bir öğrenme çerçevesi önerdiler. Çalışmalarında, çok kanallı EEG sinyallerinin frekans alanını, uzamsal özelliklerini ve frekans bandı özelliklerini MFM' yi oluşturmak için birleştirdiler ve daha sonra tasarladıkları CapsNet modelini, girilen MFM' ye göre duygu durumlarını tanımak için eğittiler. Deney sonunda % 68.28 oranında doğruluk oranına (arousal - uyarılma) ulaştılar.

Bu tez çalışması 5 ana bölümden oluşmaktadır. Birinci bölümde EEG tabanlı duygu analizi ile ilgili çalışmaları içeren literatür taraması yer almaktadır. En yaygın kullanılan yöntemlerin avantaj ve dezavantajları yorumlanmaktadır.

İkinci bölümde, EEG tabanlı duygu analizi hakkında bilgiler verilmektedir. Beyin dalgalarının türleri, EEG sinyalinin genel özellikleri, çalışmada kullanılan EEG veri setleri, ön işlem süreçleri, kanal seçimi ve özellik çıkarma yöntemleri ile ilgili ayrıntılı bilgiler bu bölümde verilmektedir.

Üçüncü bölümde, duygu sınıflandırmada kullanılacak olan derin sinir ağları ile ilgili bilgiler yer almaktadır. Ayrıca çalışmada kullanılan gelişmiş kapsül ağı modeli detaylı olarak bu bölümde açıklanmıştır.

Dördüncü bölümde deneysel çalışmalar yer almaktadır. Sunulan yöntem üzerine iki ayrı çalışma yapılmıştır. Birinci çalışmada Seed EEG veri tabanı kullanılarak, literatürde bulunan en etkili kanallar tespit edildikten sonra Welch güç spektral

yoğunluęu tahminine dayanan yöntem ile özellikleri çıkarılıp görsel hale getirilerek eğitim ve test verileri elde edilmiş, ardından oluşturulan gelişmiş kapsül aęı tabanlı derin öğrenme modeli bu verilerle eğitilmiştir. Aynı zamanda elde edilen sonuçlar CNN, AlexNet, DenseNet, VGG11, LeNet ve ResNet ile karşılaştırılmıştır. Son olarak yöntem, Dreamer ve Deap veri setleri ile test edilmiştir. İkinci çalışmada ise ABC algoritmasının dört farklı varyasyonu ile Seed EEG veri setindeki en etkili kanallar tespit edilmiş, tespit edilen kanalların Welch güç spektral yoğunluęu tahmini ile özellikleri çıkarılmış ve gelişmiş kapsül aęı tabanlı model ile sınıflandırılmıştır.

Beşinci ve son bölümde, yapılan çalışmalardan elde edilen tüm sonuçlar ve karşılaştırmalar yorumlanmaktadır. Ayrıca gelecekte yapılacak çalışmalar için bazı öneriler yer almaktadır.

BÖLÜM 2

EEG TABANLI DUYGU ANALİZİ

Beyin dalgaları (brainwaves), merkezi sinir sistemindeki ritimsel veya tekrarlı sinirsel aktivite kalıplarıdır. Beynin çeşitli bölgeleri aynı anda aynı beyin dalgası frekansını yaymaz. Beyin dalgası kalıpları her birey için benzersizdir. Yaygın olarak tanınan beş beyin dalgası vardır. Bunlar alfa, teta, beta, delta ve gama dalgalarıdır [40].

Çizelge 2.1. Beyin dalgaları [41].


Beyin Dalgası	Hz	Aktivite	Bölge
Alfa	8-13	Meditasyon / Rahatlama Düşünme / Görselleştirme Problem çözme	Parietal
Teta	4-8	Derin gevşeme / Meditasyon	Frontal
Beta	12-40	Artan uyanıklık / Konsantrasyon Aktif konuşma / Spor / Sunum	Frontal ve Posterior arası
Delta	0.5-4	Derin rüyasız uyku Derin meditasyon / Patolojik durumlar	-
Gama	25-40	İçgörü patlamaları Üst düzey işleme	-

Delta dalgaları, insanlarda kaydedilen en yavaş beyin dalgalarıdır. En sık bebeklerde ve küçük çocuklarda bulunurlar ve en derin gevşeme ve onarıcı, iyileştirici uyku seviyeleri ile ilişkilidirler. Delta dalgaları, beyin yaralanmalarında, öğrenme problemlerinde belirgin şekilde görülür. Bu dalga bastırılırsa, vücudu gençleştirememeye, beyni canlandıramama ve kötü uyku gibi etkilere yol açar. Yeterli delta dalgaları üretimi, tamamen yenilenmiş hissetmemize yardımcı olur ve bağışıklık sistemini, doğal iyileşmeyi ve onarıcı/derin uykuyu destekler.

Teta dalgaları, 4-8 Hz aralığında değişen frekanslara sahiptir. Genellikle uyuşukluk ve meditasyon esnasında ortaya çıkmaktadır. Alfa dalgaları, rahat ve sakin anlarda, gözler

açıkken ve uyanıkken gözlemlenirler. 8-13 Hz aralığında değişen frekanslara sahiptir. Beta dalgaları, 13-30 Hz aralığında değişen frekanslara sahiptir. Aktif düşünce ya da konsantrasyon durumlarında gözlemlenir. Gama dalgaları, 25-40 Hz aralığında değişen frekanslara sahiptir. Beynin en hızlı elektriksel aktivite sergilediği dalga türüdür [42].


EEG, beyin dalgalarının elektriksel yöntemlere dayanarak ölçülmesi ve izlenmesidir. Elektrotlar kafa derisi boyunca yerleştirilerek beyindeki nöronların iyonik akımdan kaynaklanan voltaj değişimlerini ölçer [43] (Şekil 2.1). Ancak bu ölçümlemenin önündeki en büyük engel beyindeki elektriksel potansiyel genliklerinin çok düşük olmasıdır. Elektrot ile beyin yüzeyi arasındaki mesafe arttıkça ölçümdeki zorluk seviyesi de artmaktadır. EEG kayıtlarının net olarak alınabilmesi için kaydın alınacağı yerde daha derine inmek gerekmektedir. Ayrıca EEG cihazının kaydedebildiği kanal sayısı da oldukça önemlidir. Düzgün bir EEG verisi alabilmek için en az 16 elektrotlu bir EEG kayıt sistemine ihtiyaç vardır [44].



Şekil 2.1. Tek kanal EEG kaydı örneği.

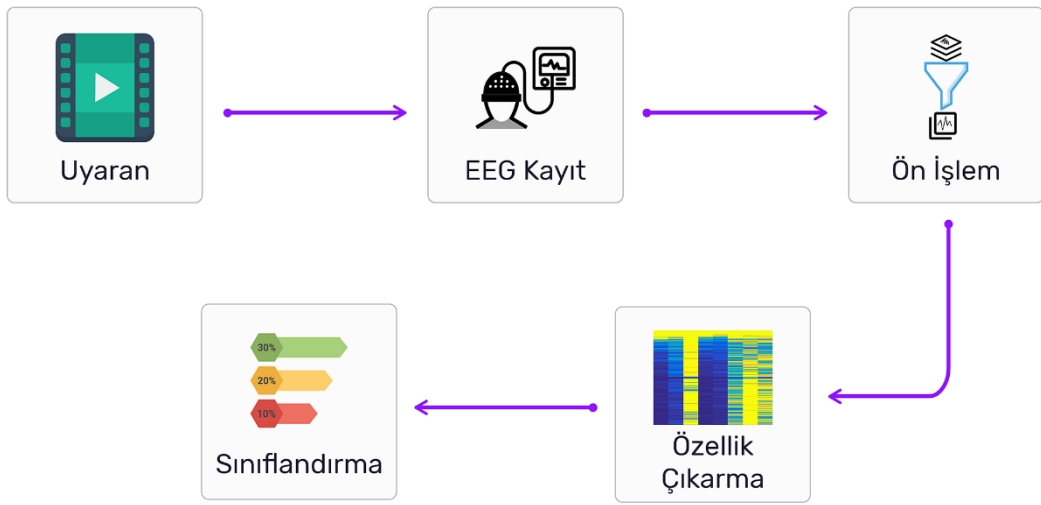
EEG kayıt sisteminde ölçüm işlemini sağlayan elektrotlar, dünya genelinde kabul görmüş belirli düzenlere göre kafa derisine yerleştirilirler. Bunlardan bir tanesi

uluslararası 10-20 sistemidir. Bu sistem, baş üzerindeki kemik işaret noktaları arasındaki uzaklıkları referans alır ve başı bir boydan bir boya kateden ve toplam uzunluklarının %10 veya %20'si kadar aralıklarla ayrılan bir çizgi meydana getirir. Elektrotlar çizgideki kesişme noktalarına konumlandırılır. Böylece simetrik ve tekrarlanabilen bir yerleşim sağlanır. Bu sayede farklı hasta ve laboratuvarlardan kaydedilen EEG verilerinin karşılaştırılması mümkün hale gelir. Ölçümlerde genellikle kayıt ve toprak elektrotları kullanılır. Kayıt elektrotları bir harf, bir satırlı harfi veya rakam ile gösterilir. Harf, elektrotun bulunduğu bölgeyi tanımlar. Bu bölgelere frontopolar (FP), frontal (F), santral (C), temporal (T), parietal (P), oksipital (O) ve auriküler (A) adı verilir. Orta hat yerleşimini gösteren ise satır altı "z" veya lateral (yan) yerleşimi gösteren bir rakamdır. Tek sayılar sol yandaki elektrotları, çift sayılar ise sağ yandaki elektrotları temsil eder (Şekil 2.2). Uluslararası 10-20 sisteminde, rakamlar orta hattan uzaklaştıkça büyür. Ancak, temporal ve frontopolar elektrotların rakamları önden arkaya doğru ilerledikçe artış gösterir [45-50].



Şekil 2.2. Uluslararası 10-20 sistemi.

Elektroensefalografi tabanlı duygu analizi beş ana aşamadan oluşur. İlk olarak, kullanıcılar özel olarak tasarlanmış ya da gerçek dünyada bulunan uyaranlara maruz kalırlar. Daha sonra beyin aktiviteleri eşzamanlı olarak EEG sinyalleri şeklinde kaydedilir. Ardından, gürültü ve istenmeyen yapıtları (artefakt) gidermek için ham veriler ön işleme tabi tutulur. Son olarak işlenen bu verilerin özellikleri çıkartılır ve çıkartılan özelliklere göre bir sınıflandırıcı modeli eğitilir. Eğer istenirse, kullanıcının güncel duygusal durumları belirlendikten sonra bir geri bildirim uygulanabilir (Şekil 2.3).



Şekil 2.3. EEG tabanlı duygu analizi.

2.1. EEG VERİ TABANLARI

EEG ve sensör verileri laboratuvar ortamında direk cihazdan kaydedileceği gibi kategorize edilmiş, kıyaslamalı ve halka açık veri tabanları da kullanılabilir.

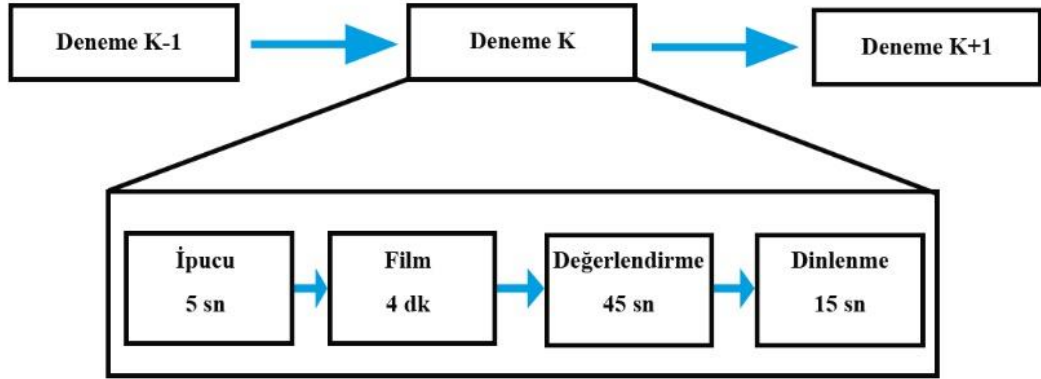
2.1.1. Seed EEG Veri Tabanı

Seed EEG veri tabanında, uyaran olarak materyal havuzundan her biri yaklaşık 4 dakika süreli 15 film klipi seçilmiştir. Her film klipi, duygusal anlamları (olumlu, tarafsız ve olumsuz) en üst düzeye çıkarmak için düzenlenmiştir. Çizelge 2.2, deneylerde kullanılan film klipleri ile ilgili detayları vermektedir.

Çizelge 2.2. Deneysel olarak kullanılan film klipleri [9].

No	Etiket	Klip Kaynağı
1	Negatif	Tangshan Earthquake
2	Negatif	1942
3	Pozitif	Lost in Thailand
4	Pozitif	Flirting Scholar
5	Pozitif	Just Another Pandora' s Box
6	Nötr	World Heritage In China

Deneysel olarak, 7 erkek ve 8 kadın olmak üzere isimleri gizlenmiş toplam 15 kişi katılmıştır. Her deney için toplam 15 deneme vardır ve 3 kez tekrar edilmiştir. Sunum sırası, aynı duyguyu hedef alan iki film klipinin arka arkaya gösterilmemesi için düzenlenmiştir. Her klipten önce 5 saniye ipucu ve her klipten sonra 45 saniye geri bildirim (değerlendirme) yapılmıştır (Şekil 2.4). Geri bildirim için katılımcılara, her klip izlendikten sonra ilgili anketi doldurarak duygusal tepkilerini bildirmeleri söylenmiştir. Deneyler sabah veya öğleden sonra sessiz bir ortamda, uluslararası 10-20 sistemine göre 62 kanallı elektrot başlığından 1000 Hz. örnekleme hızında bir ESI NeuroScan sistemi kullanılarak kaydedilmiştir [9, 25].



Şekil 2.4. Deney protokolü.

2.1.2. Dreamer Veri Tabanı

Dreamer veri tabanı, 23 deneğin (14 erkek ve 9 kadın) 18 adet film klipini izlerken 14 elektrotlu EEG kayıt cihazı ile elde edilen verileri içerir. Her film klipi 65 saniye ile 393 saniye arasında sürer. Film kliplerinin ortalama uzunluğu 199 saniyedir. Bu sürenin bir duyguyu ortaya çıkarmak için yeterli olduğu düşünülür. Veri toplama,

deneklerin her yeni denemede nötr duygu durumuna geçmelerine yardımcı olmak için nötr bir film klibinin izlenmesi ile başlar. Tüm EEG sinyalleri 128 Hz. Örnekleme hızında kaydedilir. Bir film klipi izlendikten sonra denekler uyarılma (arousal), değerlik (valence) ve baskınlık (dominance) değerlerini 1 ile 5 arası derecelendirirler. Dreamer veri seti deneysel sinyaller, temel sinyaller ve etiketlerden oluşur [51, 52].

Çizelge 2.3. Dreamer veri formatı [51].

Veri Adı	Boyut	İçerik
Deneysel Sinyaller	18 x 14 x 25 472	Video / deneme x kanal x veri
Temel Sinyaller	18 x 14 x 7808	Video / deneme x kanal x veri
Etiketler	18 x 3	Video / deneme x etiket (uyarılma, değerlik, baskınlık)

2.1.3. Deap Veri Tabanı

Deap veri tabanında, 32 deneğin birer dakikalık 40 müzik videosunu izlerken elde edilen 32 kanallı EEG sinyalleri ve 8 kanallı çevresel fizyolojik sinyalleri bulunur. Her EEG sinyali, gevşeme durumunda kaydedilen 3 saniyelik bir taban çizgisi sinyali ve uyarılma altında kaydedilen 60 saniyelik bir deneysel sinyal içerir. Katılımcılar, her videoyu izledikten sonra uyarılma, değerlik, baskınlık ve beğenme (liking) düzeylerini 1'den 9'a kadar derecelendirir [51, 53].

Çizelge 2.4. Deap veri formatı [51].


Veri Adı	Boyut	İçerik
Deneysel Sinyaller	40 x 40 x 8064	Video / deneme x kanal x veri
Etiketler	40 x 4	Video / deneme x etiket (uyarılma, değerlik, baskınlık, beğenme)

2.2. VERİ ÖN İŞLEME

Performansı elde etmek ve ya daha iyi hale getirmek için işlenmemiş ve dağınık yapıda olan verilerin belirli kurallar çerçevesinde atılması ya da değiştirilmesi işlemine ön işlem denir. Sinyallerin boyutunu küçültmek, istenmeyen yapıtlardan (artefakt) ve gürültülerden temizlemek için ön işlem süreci uygulanır.

2.2.1. Örneklem Hızının Düşürülmesi


Örneklem hızının düşürülmesi (downsampling), bir sinyalin örnekleme oranının azaltılması işlemidir. Genellikle verinin oranını veya boyutunu azaltmak için kullanılır (Şekil 2.5).



Şekil 2.5. Bir sinyalin örneklem hızının düşürülmesi.

2.2.2. Band Geçiren Filtre

Sadece belirtilen aralıktaki frekansları geçiren, bu aralığın dışındaki frekansları reddeden bir filtre türüdür (Şekil 2.6).



Şekil 2.6. Bant geçiren bir filtre için bant genişliğini (B) gösteren bir şema.

Burada f_0 merkez frekans, f_a yüksek kesme frekansı ve f_b düşük kesme frekansdır.

2.3. KANAL SEÇİMİNDE METASEZGİSEL YÖNTEMLERİN KULLANIMI

Kanal seçimi yaparken, duygusal bir uyarılma sırasında beynin en çok etkilendiği bölgeler tercih edilir [14].

Kanal seçiminde metasezgisel algoritmaların kullanımı son zamanlarda çok fazla tercih edilmektedir [15]. Metasezgisel, zorlu optimizasyon problemlerinin çözümünde son derece önemli gelişmelerle etkileyici bir araştırma alanıdır. İlk metasezgiselin önerilmesinden bu yana büyük ilerlemeler kaydedilmiştir ve her gün çok sayıda yeni algoritma önerilmeye devam etmektedir. Bu alandaki çalışmaların yakın gelecekte gelişmeye devam edeceğine şüphe yoktur. Karmaşık problemleri çözmek için bu algoritmaları kullanmanın cazibesi, çok büyük problem boyutları için bile en iyi/optimum çözümleri küçük miktarlar ile elde etmeleridir [54].

Yapay arı kolonisi (ABC), bal arısı sürülerinin yiyecek arama davranışlarını taklit eden, popülasyon tabanlı bir metasezgisel optimizasyon algoritmasıdır. Algoritma, global optimizasyon problemlerini çözmek için geliştirilmiş olsa bile, farklı problem türleri için birçok varyant vardır [55]. Gerçek hayattaki bir bal arısı sürüsüne göre algoritma, işçi ve gözcü arı olmak üzere iki tür arı içerir. İşçi arılar gerçek sürüde var olan besin kaynağını iyileştirmekten sorumludur, optimizasyon algoritmasında kendi çözümlerini geliştirmeye karşılık gelir. Gözcü arılar, algoritmada iyi çözümler olan yeni yüksek nitelikli gıda kaynaklarının geliştirilmesinden sorumludur. Algoritmanın son adımında, gözcü arılar, yeterli denemeye rağmen gelişmeyen besin kaynağı için rastgele geçerli yeni bir çözüm üretmek amacıyla kâşif arılara dönüştürülür. Bu adım, algoritmanın keşif yeteneğini geliştirir. ABC algoritmasında uygunluk değeri Eşitlik 2.1'de verilmektedir.

$$Fit(x_i) = \begin{cases} \frac{1}{1 + obj(x_i)} & obj(x_i) \geq 0 \\ 1 + |obj(x_i)| & diğ er durumda \end{cases} \quad (2.1)$$

Yüksek kaliteli çözümler için Eşitlik 2.2'de verilen olasılık değerleri kullanılır, ardından Eşitlik 2.3 kullanılarak yeni bir aday çözüm üretilir.

$$p(x_i) = \frac{Fit(x_i)}{\sum_{j=1}^N Fit(x_j)} \quad (2.2)$$

$$v_i = x_i + rand(-1,1)_i(x_i - x_n) \quad (2.3)$$

Burada x_i mevcut çözüm, x_n komşu çözüm ve v_i mevcut ve komşu çözümden üretilen aday çözümdür. $i = 1,2,3 \dots, N$ popülasyondaki her bireyin indeksini belirler. N , popülasyondaki birey sayısını gösterir. Başlangıç ve kâşif arı aşamalarında Eşitlik 2.4 kullanılarak yeni çözümler üretilir.

$$x_{i,j} = LB_i + rand(0,1) \times (UB_j - LB_j) \quad (2.4)$$

Burada i seçilen çözüm vektörünün indeksi, j seçilen karar değişkeninin indeksidir. LB ve UB sırasıyla alt ve üst sınırlar olarak tanımlanır.

Orijinal ABC algoritmasının 0/1 optimizasyon problemi olan kanal seçimini uygulayabilmesi için bazı modifikasyonlara ihtiyacı vardır. Tüm algoritmalar saf ikili karar değişkenleriyle çalışır. Eşitlik 2.3 ve Eşitlik 2.4 sürekli karar değişkenleri için uygun olduğundan, ilk ikili çözümler üretmek için yeni bir denklem veya mekanizma gereklidir. Ortak yaklaşım, bu görev için Eşitlik 2.5'te verilen Bernoulli sürecini kullanmaktır.

$$x_{i,j} = \begin{cases} 0 & rand < 0.5 \\ 1 & diğer durumda \end{cases} \quad (2.5)$$

2.3.1. İkili ABC Algoritması (BinABC)

ABC algoritması, ikili alan problemlerini uygulamak için Kiran vd. [56] tarafından BinABC ismi ile modifiye edilmiştir. BinABC algoritmasında, Eşitlik 2.6, yeni bir aday çözüm üretmek için mantıksal XOR işleminin kullanıldığı Eşitlik 2.3 ile değiştirilmiştir.

$$v_{i,j} = x_{i,j} \oplus v(x_{i,j} \oplus x_{n,j}) \quad (2.6)$$

Burada v mantıksal NOT operatörünün kullanılıp kullanılmadığını tespit etmek için önceden belirlenmiş eşik değeridir. Rastgele üretilen sayı v değerinden büyükse parantez içindeki değer tamamlanır.

2.3.2. Farklılık Tabanlı ABC Algoritması (DisABC)

Farklılık tabanlı ABC algoritması (DisABC), mevcut ve komşu çözüm arasında bir benzerlik ölçüsü kullanan Kashan vd. [57] tarafından önerilmiştir. Benzerlik değeri, iki çözüm arasında aynı konumdaki aynı bitlerin sayısını kullanan Eşitlik 2.7 ile hesaplanır. Farklılık ölçüsü, Eşitlik 2.8'de kişinin benzerlik değerinin tümleyeni bulunarak hesaplanır.

$$similarity(x_i, x_j) = \frac{M_{11}}{M_{01} + M_{10} + M_{11}} \quad (2.7)$$

$$dissimilarity(x_i, x_j) = 1 - similarity(x_i, x_j) \quad (2.8)$$

Burada M_{01} ve M_{10} aynı konumdaki her iki çözümün farklı bitlerin sayısını temsil ederken, M_{11} aynı konumdaki her iki çözümün 1 sayısını temsil eder. Eşitlik 2.9 ve 2.10, aday çözümdeki 1 ve 0 değerlerinin sayısını belirlemek için kullanılır. Ana amaç, mevcut ve aday çözümler arasındaki minimum boşluktur.

$$dissimilarity(v_i, x_i) \approx \emptyset \times dissimilarity(x_i, x_j) \quad (2.9)$$

$$\min |dissimilarity(v_i, x_i) - \emptyset \times dissimilarity(x_i, x_j)| \quad (2.10)$$

Buna göre;

$$\begin{aligned} M_{11} + M_{01} &= n_1 \\ M_{10} &\leq n_0 \\ M_{10}, M_{11}, M_{01} &\geq 0 \text{ ve } \in \mathbb{Z} \end{aligned} \quad (2.11)$$

Burada \emptyset ölçekleme faktörü için bir katsayıdır, n_1 ve n_0 , seçilen çözüm x_i 'de 1 ve 0 değerindeki bit sayısını temsil eder. Mevcut ve aday çözüm için yeni M değerleri elde edildikten sonra, farklılık işleminin tersi yapılır.

2.3.3. Geliştirilmiş İkili ABC Algoritması (iBinABC)

Orijinal ABC ve BinABC algoritmalarında aday çözüm sürecinde yalnızca bir karar değişkeni güncellendiğinden, diğer sürü zekası algoritmalarına kıyasla yakınsama hızı düşüktür. Bu sorunun üstesinden gelmek için binABC'nin geliştirilmiş versiyonu, Eşitlik 2.12'de verildiği gibi hesaplanan farklı sayıda karar değişkenini güncellemektedir.

$$d_t = rand(0, \alpha) + e^{-\left(\frac{t}{t_{max}}\right)^{\times 0.1 \times D}} + 1 \quad (2.12)$$

Burada α , D aralığında güncellenecek minimum bit sayısını, t ve t_{max} sırasıyla mevcut ve maksimum yineleme sayısını temsil eder. ibinABC'nin diğer modifikasyonu, v değerini mevcut ve komşu çözümlerle kontrol etmektedir ve [56], sömürü faktörü (exploitation factor) olarak Eşitlik 2.6'da 0.5'e sabitlenmiştir. Seçilen ve komşu çözümlerin uygunluk değerlerini kullanarak v değerini belirlemek için Eşitlik 2.13 kullanılır.

$$v = \begin{cases} Q_{max} - \left(\frac{Q_{max} - Q_{min}}{t_{max}}\right) \times t & F(x_n) < F(x_i) \\ 0 & \text{diğer durumda} \end{cases} \quad (2.13)$$

Burada Q_{max} ve Q_{min} sırasıyla önceden tanımlanmış aralığın üst ve alt sınırlarını temsil eder [58].

2.3.4. Yeni İkili ABC Algoritması (NBABC)

Santana vd. [59], ikili karar değişkenleri üzerinde değiştirme operatörü kullanan yeni ikili ABC (NBABC) algoritmasını önerdiler. Bu algoritmada, güncellenecek karar değişkenlerinin sayısı arama işlemi sırasında adaptif olarak belirlenir. Daha sonra

rastgele seçilen bitler ters çevrilir. Deneysel sonuçlar, NBABC algoritmasının diğer algoritmalar ile karşılaştırıldığında hem rekabetçi hem de bazı durumlarda üstün sonuçlar elde edebildiğini göstermiştir. Ayrıca, bilinen operatörler analiz edilerek ve gereksiz hesaplamalar kaldırılarak hızlı bir ikili sürüm oluşturma hedefine ulaşıldığı görülmektedir. Önerilen yöntem, yüksek boyutlu problemlerde daha iyi bir performans gösterdiğinden, NBABC algoritması gerçek uygulamaları çözmek için en iyi seçeneklerden biri olabilir.

Çizelge 2.5. NBABC Algoritması.

Girdi : x_i
Çıktı : v_i
1 Seç : x_j where $i \neq j$
2 Set boyutların sayısını güncelle (Dims)
3 Foreach $d \in Dims$ do
4 if $x_{i,d} = x_{j,d}$ then
5 $v_{i,d} = x_{i,d}$
6 end
7 else
8 $v_{i,d} = x_{i,d}$
9 end
10 Return v_i

2.4. ÖZELLİK SEÇME VE ÇIKARMA

Özellik seçimi, büyük veri kümelerinde makine öğrenmesi yöntemlerinin başarısı üzerinde zararlı etkisi olan özellikleri kaldırmak için kullanılan yöntemlere verilen isimdir. Özellik seçim yöntemleri kabaca iki kategoriye ayrılabilir: sarmalayıcılar (wrappers) ve filtreler [60]. Filtre yöntemleri, özniteliklerin değerlerine ve aralarındaki ilişkiye göre seçimler yapar. Sarmal yöntemlerde, sınıflandırıcı sonucundaki öznitelik alt kümelerinin doğruluk değerlerine göre seçim işlemi yapılır. Seçim işlemi makine öğrenimi modeli çalıştırılmadan yapıldığından, filtre yöntemleri sarmal yöntemlerden daha hızlı çalışır. Ancak literatürdeki çalışmalardan da açıkça görülebileceği gibi sarmal yöntemlerin seçim başarısı daha yüksektir [61]. Özellik seçim problemi bir maksimizasyon karar verme problemine dönüştürüldüğünde, amaç fonksiyonu Eşitlik 2.14'teki gibi temsil edilebilir. Eşitlikte x seçilen alt kümeyi, α ve β başarı ile özellik

sayısı arasındaki oranı, $Acc(x)$ sınıflandırma başarısını, R veri kümesindeki toplam özellik sayısını temsil eder.

$$Fitness(x) = \alpha Acc(x) + \beta \frac{|x|}{|R|} \quad (2.14)$$

Bu çalışmada öznitelik sayısı makul ve sınıflandırma başarısı daha önemli olduğundan $\alpha = 1, \beta = 0$ alınmıştır.

2.4.1. Welch Güç Spektral Yoğunluğu Tahmini

EEG sinyallerinin, derin öğrenme kullanılarak analiz edilebilmesi için genellikle sinyal değerlerinin pikseller tarafından temsil edildiği resim formatına dönüştürülmesi tercih edilir. Ancak EEG sinyallerinin görüntü veya konuşma sinyallerinden farklı olarak çok daha karmaşık yapıda olmaları bu sinyallerin analizini oldukça zor hale getirmektedir. EEG verisinin hiçbir işleme tabi tutulmadan (ham veri olarak) görüntü formatına dönüştürülmesi, elde edilen resmin oldukça karmaşık olmasına neden olacaktır. Bu durum, sınıflandırma işlemi için kullanılacak modelin doğruluğunu olumsuz yönde etkileyecektir.

Güç spektral yoğunluğu (PSD), frekans spektrumuna göre sinyal gücünü verir. PSD'nin iyileştirilmiş hali ise Welch tarafından önerilen yöntemdir [62]. Bu yöntem (Welch PSD), öncelikle zaman serisi verilerini bölümlere ayırır. Daha sonra her bir bölümün değiştirilmiş bir periodogramını hesaplar ve ardından elde edilen PSD tahminlerinin ortalamasını alır.

$$\hat{S}_{xx}^i(f) = \frac{Y_s}{K.M} \left| \sum_{n=1}^{M-1} x_i(n)w(n)e^{-j2\pi fn} \right|^2 \quad (2.15)$$

Burada i iyileştirilmiş periodogramı, $f = f_s$ normalize edilmiş frekans değişkenini, Y_s ölçekleme faktörünü ve $w(n)$ pencereleme fonksiyonunu ifade eder.

K normalize sabiti olup;

$$K = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (2.16)$$

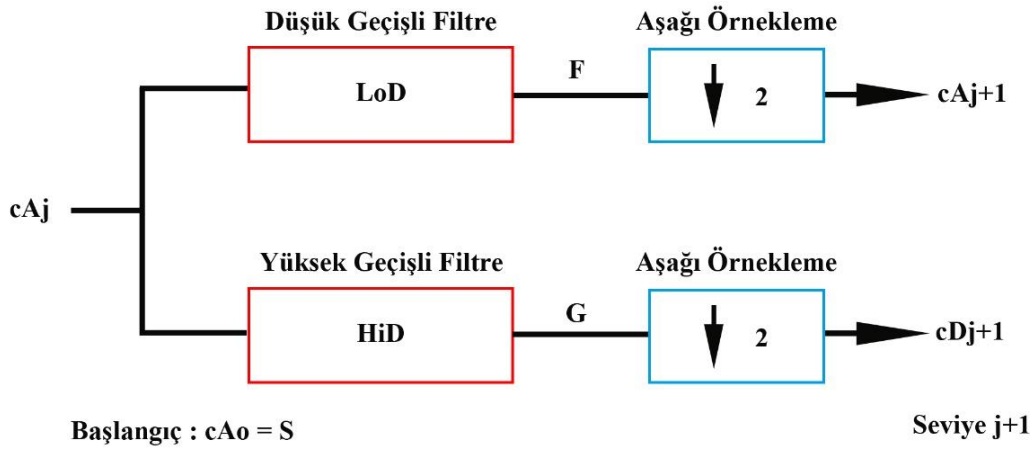
şeklinde ifade edilir. Welch PSD ise;

$$\hat{P}_w(f) = \frac{1}{L} \sum_{i=0}^{L-1} \hat{S}_{xx}^i(f) \quad (2.17)$$

şeklinde ifade edilir. Burada L işaretin uzunluğudur.

2.4.2. Ayrık Dalgacık Dönüşümü

Dalgacık Dönüşümü, Fourier dönüşümünün bir uzantısı olarak düşünülebilir. Ancak, tek ölçekli (zaman veya frekans) çalışmak yerine çok ölçekli olarak çalışır ve durağan olmayan sinyallerle ilgili problemleri ele alır [63].



Şekil 2.7. Ayrık Dalgacık Dönüşümü.

N uzunlukta bir sinyal verildiğinde, ayrık dalgacık dönüşümü en fazla $\log_2 N$ adımdan oluşur. S (cA_0) değerinden başlayarak, ilk adımda düşük geçişli filtre (LoD) ve yüksek geçişli filtre (HiD) işleminden sonra elde edilen çıktılara aşağı örnekleme uygulanarak iki katsayı kümesi üretilir. Bunlara yaklaşım katsayıları cA_1 ve detay katsayıları cD_1 adı verilir. Bir sonraki adımda, cA_1 yerine geçen yeni katsayılar ile aynı şekilde cA_2 ve cD_2 üretilir (Şekil 2.7). Bu işlem adım sayısı kadar devam eder [64-66].

BÖLÜM 3

DERİN ÖĞRENME TABANLI EEG DUYGU SINIFLANDIRMA

Yapay zeka, bilgisayar biliminde biyolojik beyindeki nöron ağının zekasını baz alan popüler bir alandır. Yapay sinir ağı, ağırlıklı sinapslarla birbirine bağlanan katmanları ve nöronları içerir [67]. Ağırlıklar, ağı öğrenmesini sağlayacak şekilde geri yayılım (backpropagation) yoluyla ayarlanır [68, 69]. Bir nöronun tetiklenmesi ise aktivasyon fonksiyonu tarafından kontrol edilir [70].

$$x = \sum_{i=1}^n x_i w_i \quad (3.1)$$


Burada x değeri, $i = 1$ 'den n 'ye olmak üzere x_i girişlerinin ve w_i ağırlık değerlerinin ağırlıklı toplamını ifade eder.

3.1. AKTİVASYON FONKSİYONLARI

Bir aktivasyon fonksiyonu, bir nöronun aktive edilip edilmeyeceğine karar verir. Bu, nöronun ağı girişinin önemli olup olmadığına daha basit matematiksel işlemler kullanarak tahmin sürecinde karar vereceği anlamına gelir. Aktivasyon fonksiyonunun birincil rolü, düğümünden alınan toplam ağırlıklı girdiyi, bir sonraki gizli katmana veya bir çıktı değerine dönüştürmektir.

İkili adım fonksiyonu, bir nöronun etkinleştirilip etkinleştirilmemesi gerektiğine karar veren bir eşik değerine bağlıdır. Aktivasyon fonksiyonuna gönderilen girdi, belirli bir eşik ile karşılaştırılır; eğer girdi büyükse, o zaman nöron aktive olur, aksi takdirde deaktive edilir, yani çıktısı bir sonraki gizli katmana iletilmez (Şekil 3.1).

$$f(x) = \begin{cases} 0, & x < 0 \\ 1 & x \geq 0 \end{cases} \quad (3.2)$$




Şekil 3.1. İkili adım fonksiyonu.

İkili adım fonksiyonları birden fazla değere sahip çıktılar sağlayamadığı için çok sınıflı problemler için kullanılamaz. Ayrıca adım fonksiyonunun gradyanı sıfırdır, bu durum geri yayılım sürecinde engele neden olur.

Lineer aktivasyon fonksiyonu, girdinin ağırlıklı toplamına hiçbir şey yapmaz, yalnızca kendisine verilen değeri döndürür (Şekil 3.2).

$$f(x) = x \quad (3.3)$$



Şekil 3.2. Lineer aktivasyon fonksiyonu.


Lineer aktivasyon fonksiyonun türevi sabit olduğundan ve x girişiyle hiçbir ilişkisi olmadığından geri yayılımı kullanmak mümkün değildir. Ayrıca doğrusal bir etkinleştirme işlevi kullanılırsa, sinir ağının tüm katmanları tek bir katmana indirgenmiş olur. Sinir ağındaki katman sayısı ne olursa olsun, son katman yine de ilk katmanın doğrusal bir işlevi olacaktır. Doğrusal bir aktivasyon işlevi, sinir ağını sadece bir katmana dönüştürür.

Doğrusal olmayan aktivasyon fonksiyonu geri yayılıma izin verir çünkü giriş verisinden etkilenir ve girdi nöronlarındaki hangi ağırlıkların daha iyi bir tahmin sağlayabileceğini anlamayı sağlar. Elde edilen çıktı, birden çok katmandan geçen doğrusal olmayan bir girdi kombinasyonudur. Bu yüzden birden çok nöron katmanının kullanılmasına izin verir.

3.1.1. Sigmoid Fonksiyonu

Sigmoid fonksiyonu, aldığı girdi değerini 0 ile 1 aralığına dönüştürür. Girdi değeri pozitifse ne kadar yakınsa çıktı değeri 1'e yakın olur. Girdi değeri negatifse yaklaştığında ise çıktı değeri 0'a yakın olur (Şekil 3.3).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.4)$$




Şekil 3.3. Sigmoid fonksiyonu.

Sigmodi fonksiyonu, çıktı olarak olasılığın tahmin edilmesi gereken modeller için yaygın olarak kullanılır. Herhangi bir şeyin olasılığı yalnızca 0 ile 1 aralığında olduğundan, çıktı aralığı nedeniyle sigmoid doğru seçimdir. Ayrıca fonksiyon türevlenebilirdir ve düzgün bir gradyan sağlar, yani çıktı değerlerinde sıçramaları önler.

3.1.2. Hiperbolik Tanjant Fonksiyonu

Hiperbolik tanjant fonksiyonu, sigmoid fonksiyonuna çok benzer. Aldığı girdi değerini -1 ile 1 aralığına dönüştürür. Girdi değeri pozitif ne kadar yakınsa çıktı değeri 1'e yakın olur. Girdi değeri negatife yaklaştığında ise çıktı değeri -1'e yakın olur (Şekil 3.4).

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (3.5)$$




Şekil 3.4. Hiperbolik tanjant fonksiyonu.

Tanh aktivasyon fonksiyonunun çıktısı sıfır merkezlidir; bu nedenle, çıktı değerleri güçlü bir şekilde negatif, nötr veya güçlü bir şekilde pozitif olarak kolayca eşlenebilir. Ayrıca verileri merkezlemeye yardımcı olur ve bir sonraki katman için öğrenmeyi çok daha kolay hale getirir.

3.1.3. ReLU Fonksiyonu

Doğrusal bir fonksiyon izlenimi vermesine rağmen, ReLU bir türev işlevine sahiptir (Şekil 3.5). Bu durum onu hesaplama açısından verimli hale getirirken aynı zamanda geri yayılıma izin verir [71].

$$f(x) = \max(x, 0) \quad (3.6)$$




Şekil 3.5. ReLU fonksiyonu.

Yalnızca belirli sayıda nöron etkinleştirildiğinden, ReLU fonksiyonu, sigmoid ve tanh ile karşılaştırıldığında hesaplama açısından çok daha verimlidir. Ayrıca kayıp fonksiyonunun global minimuma doğru gradyan inişinin yakınsamasını hızlandırır.

3.1.4. Leaky ReLU Fonksiyonu

ReLU fonksiyonunun geliştirilmiş bir versiyonudur. Leaky ReLU, negatif alanda küçük bir pozitif eğime sahiptir. Negatif giriş değerleri için bile geri yayılımı etkinleştirebilir (Şekil 3.6).

$$f(x) = \max(0.1x, x) \quad (3.7)$$




Şekil 3.6. Leaky ReLU fonksiyonu

3.1.5. Parametrik ReLU Fonksiyonu

Parametrik ReLU, eksenin sol yarısı için eğimin sıfır olması sorununu çözmeyi amaçlayan bir başka ReLU çeşididir. Bu fonksiyon, a argümanı olarak fonksiyonun negatif kısmının eğimini sağlar. Geri yayılım yapılarak a 'nın en uygun değeri öğrenilir (Şekil 3.7).

$$f(x) = \max(ax, x) \quad (3.8)$$




Şekil 3.7. Parametrik ReLU fonksiyonu.

Burada a , negatif deęerler için eęim parametresidir. Parametrelili ReLU fonksiyonu, Leaky ReLU fonksiyonu ölü nöronlar sorununu çözmeye başarısız olduęunda ve ilgili bilgiler başarılı bir şekilde bir sonraki katmana aktarılmadıęında kullanılır.

3.1.6. Üstel Lineer Birim (ELU) Fonksiyonu

Fonksiyonun negatif kısmının eęimini deęiřtiren bir ReLU çeřididir. ELU, düz bir çizgi ile Leaky ReLU ve Parametrik ReLU fonksiyonlarının aksine negatif deęerleri tanımlamak için bir log eęrisi kullanır (Şekil 3.8).

$$\begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - 1) & x \leq 0 \end{cases} \quad (3.9)$$



Şekil 3.8. ELU fonksiyonu.

ELU fonksiyonunda dahil edilen üstel işlem nedeniyle hesaplama süresi artar. Ayrıca a 'nın öğrenimi gerçekleşmez.

3.1.7. SoftMax Fonksiyonu

SoftMax fonksiyonu, çok sınıflı sınıflandırma problemlerinde kullanılır [70, 72, 73].


$$P(f(x)_i = \frac{1}{x}) = \frac{e^{-x^i}}{\sum_{j=1}^n e^{-x^j}} \quad (3.10)$$

Burada n çıkış sınıfı sayısını, i ve j parametreleri, i 'inci ve j 'inci sınıfları, $P(f(x)_i)$ ise i 'inci sınıf için öngörülen olasılığı temsil eder.

3.1.8. Swish Fonksiyonu

Google'daki araştırmacılar tarafından geliştirilen bir aktivasyon fonksiyonudur. Swish, görüntü sınıflandırma, makine çevirisi gibi çeşitli zorlu alanlara uygulanan derin ağlarda ReLU aktivasyon fonksiyonuyla tutarlı bir şekilde eşleşir ve ya ondan daha iyi performans gösterir (Şekil 3.9).

$$f(x) = x \times \text{sigmoid}(x) \quad (3.11)$$




Şekil 3.9. Swish fonksiyonu.

3.1.9. GELU Fonksiyonu

ReLU, ELU ve Parametrik ReLU gibi fonksiyonlar, sinir ağlarının, sigmoid fonksiyonlarından daha hızlı ve daha iyi yakınsamasını sağlamıştır. Ayrıca dropout, birkaç aktivasyonu rastgele 0 ile çarparak modeli düzenler. Bu yöntemlerin ikisi

birlikte bir nöronun çıktısına karar verir. Ancak ikisi birbirinden bağımsız çalışır. GELU bunları birleştirmeyi amaçlar (Şekil 3.10).

$$\begin{aligned}
 f(x) &= xP(X \leq x) = x\Phi(x) \\
 &= 0.5x \left(1 + \tanh \left[\sqrt{\frac{2}{\pi}} (x + 0.044715x^3) \right] \right)
 \end{aligned} \tag{3.12}$$




Şekil 3.10. GELU fonksiyonu.

GELU fonksiyonunun doğrusal olmama durumu, ReLU ve ELU fonksiyonlarından daha iyidir ve bilgisayarla görme, doğal dil işleme ve konuşma tanıma alanlarındaki tüm görevlerde performans iyileştirmeleri sağlar.

3.1.10. SELU Fonksiyonu

SELU, kendi kendini normalleştiren ağlar için tanımlanmıştır ve her katmanın önceki katmanlardan ortalamayı ve varyansı koruduğu anlamını taşıyan dahili normalleştirme ile ilgilenir. SELU, ortalama ve varyansı ayarlayarak bu normalleştirmeyi sağlar (Şekil 3.11). Dahili normalleştirme, harici normalleştirmeden daha hızlıdır, bu da ağın daha hızlı yakınsadığı anlamına gelir.

$$f(x) = \lambda \begin{cases} \alpha(e^x - 1), & x < 0 \\ x, & x \geq 0 \end{cases} \tag{3.13}$$



Şekil 3.11. SELU fonksiyonu.

Yapay sinir ağlarında bir diğer önemli konu maliyet fonksiyonu hesabıdır. Genellikle Sinir ağları, ortalama kare hatası (Mean Square Error - MSE) olarak adlandırılan bir maliyet fonksiyonunu hesaplayarak öğrenme işlemini gerçekleştirir. Ancak çıkış hatasını belirlemek için kullanılabilen bir çok maliyet fonksiyonu vardır. Örneğin gradyan iniş (Gradient Descent - GD) bunlardan birtanesidir [67].

3.2. SINIFLANDIRMA MODELLERİNDE BAŞARI KRİTERLERİ

Makine öğrenmesinde, hedef verisi belli olan veri setlerini kullanan sınıflandırma modellerinin performansını ölçmek için genellikle karmaşıklık matrisi kullanılır. Pozitif ve negatif örnekleri barındıran test verisinin ne ölçüde sınıflandırıldığını bu matris gösterir.

Çizelge 3.1. Karmaşıklık matrisi.

Gerçek Pozitif	Gerçek Negatif	
Doğru Pozitif	Yanlış Pozitif	Tahmin Pozitif
Yanlış Negatif	Doğru Negatif	Tahmin Negatif

Keskinlik (Precision), tüm pozitif sınıflardan, doğru tahmin edilenlerin oranıdır.

$$Kesinlik = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Pozitif} \quad (3.14)$$

Duyarlılık (Recall), tüm pozitif ve negatif sınıflardan doğru tahmin edilenlerin oranıdır.

$$Duyarlılık = \frac{Doğru Pozitif}{Doğru Pozitif + Yanlış Negatif} \quad (3.15)$$

F1-Skoru (f1-Score), kesinlik (Eşitlik 3.5) ve duyarlılık (Eşitlik 3.6) değerlerini aynı anda ölçmeyi sağlar.


$$F1 - Skoru = 2 \times \frac{Duyarlılık \times Kesinlik}{Duyarlılık + Kesinlik} \quad (3.16)$$

Doğruluk (Accuracy), ağın sınıflandırmayı hangi oranda doğru yaptığını gösteren değerdir. Kayıp (Loss) değeri ise, tasarlanan modelin hata oranını belirtir.

$$Doğruluk = \frac{Doğru Pozitif + Doğru Negatif}{Doğru Pozitif + Doğru Negatif + Yanlış Pozitif + Yanlış Negatif} \quad (3.17)$$

3.3. EVRİŞİMLİ SİNİR AĞLARI (CNN)

Bilgisayarlı görüntü işlemlerinde yaygın olarak kullanılan sinir ağıdır (Şekil 3.12).



Şekil 3.12. Evrişimli Sinir Ağı.

Evrşim katmanında NxM boyutunda bir filtre (kernel), özellikleri otomatik olarak çıkarmak için giriş görüntüsünü tarar. Filtre görüntüden daha küçüktür ve bir özellik

haritası oluşturmak için verilen adım sayısına göre görüntü boyunca hareket ettirilir. Adım sayısı ne kadar büyük olursa özellik haritası o ölçüde küçük olur. İki ve daha büyük adım sayısı kullanıldığında görüntünün bazı özellikleri kaybedilir. Mümkün olduğu kadar çok özelliği korumak için birkaç farklı kernel kullanılır. Ayrıca modeli doğrusallıktan kurtarmak ve hesaplama karmaşıklığını azaltmak için evrişim katmanından sonra ReLU aktivasyon fonksiyonu kullanılabilir [67].

Farklı görüntülerde aynı nesnenin tanınması ve oluşturulan modelin ihtiyaç duyduğu kaynak (bellek vb.) ihtiyacını azaltmak için ortaklama (havuzlama) işlemi gerçekleştirilir. Maksimum, minimum, ortalama ve toplam olmak üzere 4 çeşit ortaklama işlemi bulunur [74]. Özellikleri en iyi koruyan ise maksimum ortaklama işlemidir, çünkü özellik haritasındaki en büyük sayılar görüntü üzerinde bulunan özelliklerin en yakın benzerlerinin alındığı yerleri gösterir. Elde edilen özellik haritası daha sonraki hesaplamalar için bir sütun matrisine düzleştirilir [67].

CNN'nin son kısmını tam bağlantı katmanı oluşturur. Giriş katmanları, gizli katmanlar ve çıkış katmanlarından oluşan bir sinir ağıdır. Her girişin tüm nöronlara bağlı olduğu katmandır. Sınıf skorları gibi verileri optimize etmek için kullanılır. Geri yayılım sırasında, hem ağırlıklar hem de özellik dedektörleri daha iyi performans için ayarlanır [67].

CNN'lerde, yapay sinir ağlarında bulunan maliyet fonksiyonunun eşdeğeri kayıp fonksiyonudur. Sınıflandırma görevleri için en yaygın kayıp fonksiyonu çapraz entropi fonksiyonudur [75].

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (3.18)$$

Burada q CNN'den elde edilen çıktının bir fonksiyonunu, p ise, hedef sınıfların bir fonksiyonunu ifade eder. Ancak, çapraz entropi fonksiyonu sadece sınıflandırma için yararlıdır. Regresyon için ortalama kare hatası en iyi seçenektir [67].

CNN'lerin en büyük eksikliği, görüntünün kendisinin veya içerisindeki parçaların poz, doku ve deformasyonlarının tanınmamasıdır [76]. CNN'ler ortaklama işleminin bir sonucu olarak eşdeğer değildirler ve denklikten yoksundurlar. Ayrıca ortaklama işlemi görüntüdeki bazı özellikleri kaybeder. Bu nedenle, oluşan kayıpları telafi etmek için çok sayıda eğitim verisine ihtiyaç duyarlar. Sonuç olarak, CNN'ler yanlış sınıflandırmalara daha yatkındır [77, 78]. Ayrıca, CNN'de ortaklama işlemi sonucunda görüntüyü yeniden oluşturma işlemi, yeni yöntemlerdeki yeniden yapılandırma ile karşılaştırıldığında çok daha zordur [67].

3.4. KAPSÜL AĞLARI (CapsNet)

CNN'lerin dezavantajlarından dolayı alternatif olarak kapsül ağları önerilmiştir [79]. Kapsüller CNN'lerin aksine eşdeğerdir ve vektörleri girdi ve çıktı olarak verebilen bir nöron ağından oluşur. Bu sayede kapsülün, bir görüntünün özelliklerine ek olarak deformasyonlarını ve görüntüleme koşullarını da öğrenmesini sağlar. Bir kapsül ağında her bir kapsül, bir özelliğin farklı yapılarını temsil eden bir grup nörondan oluşur. Bu yapı, önce parçalarını tanıyarak tüm nesneyi tanıyabilme avantajı sağlar.

Bir kapsüle giriş bir CNN'den gelen çıktı veya özelliklerdir. Bu özellikler kullanılan kapsül türüne göre işlenir. Bir kapsülden elde edilen çıktı, kapsül tarafından kodlanan özelliğin mevcut olma olasılığından ve örnekleme parametreleri olarak adlandırılan bir vektör değerinden oluşur. Örnekleme parametreleri, ağın poz, doku ve deformasyonları tanıma yeteneğini gösteren eşdeğerliğini temsil eder. Değişmezlik, girdilerdeki herhangi bir dönüşümden bağımsız olarak bir modelin değişmeden kalma kararının özelliğidir. Bu özelliğin bazı türleri CNN'lere özgüdür. Örneğin model, bir yüz görüntüsünde olması gereken ağız, göz burun gibi bilgileri bulmakta ve bunun yüz olduğunu tespit etmektedir. Fakat göz ile burun yer değiştirmiş olsa bile yine aynı sonuç alınmaktadır, oysa bu hatalı bir sınıflandırmadır. Eşdeğerlik, sadece görüntüdeki bir gözün varlığını değil, görüntüdeki yerini de ele alır. Başka bir deyişle eşdeğerlik, yüzdeki özelliklerin uzamsal konumunun dikkate alınmasını sağlar. Bu yüzden, kapsül ağları için önemli bir özelliktir. Genel olarak kapsül uygulamalarında üç çeşit yöntem kullanılmıştır. Bu yöntemler, dönüştüren oto-kodlayıcılar (Transforming auto-encoders) [79], kapsüller arası dinamik yönlendirme (Dynamic routing between

capsules) [76] ve beklenti-maksimizasyon yönlendirmesine dayanan matris kapsüller (Matrix capsules with em routing) [80] olarak adlandırılır [67].

İlk kapsül ağı çalışması, dönüştüren oto-kodlayıcılar (Transforming auto-encoders) [79] başlığı ile, kendisine gönderilen poz tanıma yeteneğini vurgulamak için yayımlandı. Bu çalışmada amaç, görüntülerdeki nesnelere tanıma değil, bir görüntüyü ve pozunu girdi olarak kabul etmek ve orijinal pozda aynı görüntüyü çıktı olarak almaktır. Çalışmada, birincil kapsüller (primary caps) olarak adlandırılan alt seviye ve ikincil kapsüller (secondary caps) olarak adlandırılan üst seviye kapsüller kullanılmıştır. Düşük seviyeli kapsüller, bir parça-bütün hiyerarşisi elde etmek için piksel yoğunluklarından poz parametrelerini çıkarır. Bu özellik, kapsül ağlarının çok büyük bir avantajıdır. Çünkü parçaların tanınmasıyla tüm nesne tanınabilir. Alt seviye kapsüller tarafından temsil edilen özelliklerin üst seviyedeki başka bir kapsülü aktive edebilmeleri için doğru uzamsal ilişkiye sahip olmaları gerekir. En basit şekliyle, sadece poz değerleri olarak x ve y konumlarına sahip 2 boyutlu (2D) görüntüler ve kapsüller kullanılır. Öğrenme işleminden sonra, ağı bir resim ve gerekli konum değişiklikleri Δx ve Δy verildiğinde çıktı olarak pozda belirtilen değişim ile görüntü alınabilir. Ancak, bu çalışmanın en önemli dezavantajı nesnenin pozlarının girdi olarak sağlanması ihtiyacıdır [67].

Kapsül ağları ile ilgili diğer bir çalışmada [76] ise kapsül, aktivite vektörleri ile temsil edilen örnekleme parametreleri ve özelliğin var olma olasılığını temsil eden vektör uzunluğu ile tanımlanan bir grup nörondan oluşur. Bu yapıda nesne pozlarının girdi olarak verilmesi gerekmez. Ağ, evrişim katmanı, birincil kapsül katmanı ve sınıf kapsül katmanından (class capsule layer) oluşur. Görüntüden özellik çıkarma işlemi evrişim katmanı tarafından gerçekleştirilir ve elde edilen çıktı birincil kapsül katmanına gönderilir. Bu katmandaki her bir kapsül, uzamsal bilgileri örnekleme parametreleri biçiminde kodlamak için bir aktivite vektörüne sahiptir. Alt seviyedeki bir kapsülün çıkış vektörü bir üst katmandaki bütün kapsüllere girdi olarak gönderilir. Üst katmandaki kapsül bu girdi verisini alır ve karşılık gelen ağırlık matrisi ile tahmin vektörünü (prediction vector) bulur. Bu değer birincil kapsülün, sınıf kapsülüne ne kadar katkı sağladığını gösterir [67].

$$\hat{u}_{j|i} = W_{ij}u_i \quad (3.19)$$

Burada $\hat{u}_{j|i}$ elde edilen sonuç, W_{ij} ağırlık matrisi ve u_i alt seviye kapsülün çıkış vektörüdür. Elde edilen tahmin vektörü ve kapsüller arasındaki anlaşmayı temsil eden bağlantı katsayısı, sınıf kapsülüne ilişkin tek bir birincil kapsülün tahmini için kullanılır. Kapsüller arasındaki anlaşma yüksekse bağlantı katsayısı artırılır, diğer durumda düşürülür. Daha sonra ezme fonksiyonunda (squashing function) kullanılmak üzere sınıf kapsülü için elde edilen tüm birincil kapsül tahminlerinin ağırlıklı bir toplamı hesaplanır.


$$s_j = \sum_{i=1}^N c_{ij} \hat{u}_{j|i} \quad (3.20)$$

Burada c_{ij} dinamik yönlendirme işlemi ile belirlenen bağlantı katsayıları olup;

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (3.21)$$

şeklinde ifade edilir. Burada b_{ij} alt seviye kapsül ile üst seviye kapsül arasındaki bağlantıyı tanımlamak için kullanılır. Başlangıç olarak sıfır değerini alır ve ezme fonksiyonuna göre güncellenir. Ezme işlemi, kapsülden elde edilen çıktının uzunluğunun bir olasılık hesabında olduğu gibi 0 ile 1 arasında olmasını sağlar [67, 78].

$$v_j = \frac{\|s_j\|^2 s_j}{1 + \|s_j\|^2 \|s_j\|} \quad (3.22)$$



Şekil 3.13. Bir kapsülün yapısı [76].

Çizelge 3.2. Dinamik yönlendirme algoritması [76].

procedure ROUTING ($\hat{u}_{j|i}, r, l$)

1. bütün kapsüller için i katman l ve kapsül j katman ($l + 1$): $b_{ij} \leftarrow 0$.
 2. **for** r iterations **do**
 3. bütün kapsüller için i katman l : $c_i \leftarrow \text{softmax}(b_i)$
 4. bütün kapsüller için j katman ($l + 1$): $s_j \leftarrow \sum_i c_{ij} \hat{u}_{j|i}$
 5. bütün kapsüller için j katman ($l + 1$): $v_j \leftarrow \text{squash}(s_j)$
 6. bütün kapsüller için i katman l ve kapsül j katman ($l + 1$): $b_{ij} \leftarrow b_{ij} + \hat{u}_{j|i} \cdot v_j$
 7. **return** v_j
-


2018 yılında ortaya konan diğer çalışmada [80] vektör çıktılarının yerine bir kapsülün girdi ve çıktılarının matris olarak temsil edilmesi öne sürüldü. Bu değişiklik, kapsüller arasındaki dönüşüm matrislerinin boyutunu azaltmayı sağladı. Ayrıca, anlaşmaya göre dinamik yönlendirme algoritması yerine de beklenti-maksimizasyon yönlendirme algoritması kullanıldı [81]. Dinamik yönlendirme algoritmasında anlaşma, iki poz vektörü arasındaki açının kosinüsü olarak ölçülür. Bu, işe yarayan bir uygulama olmasına rağmen iyi ve çok iyi bir anlaşma arasındaki ayrımı yapmakta mükemmel değildir. Ayrıca, bir kapsül tarafından temsil edilen nesnenin var olma olasılığı vektör uzunluğu yerine a parametresi ile değiştirildi. Bu yöntem, ezme işlemlerinden dönen bazı istenmeyen sonuçlardan kaçınmaya yardımcı oldu. Beklenti-maksimizasyonu yönlendirme algoritması, birkaç kapsül katmanına sahip kapsül ağlarını kullanır. Birincil katmandaki kapsül kümesi (Ω_L), her bir kapsülün poz matrisini (M) ve aktivasyon olasılığını (a) temsil eden alanlardan oluşur. Alt ve üst seviye kapsül arasında eğitilebilir bir dönüşüm ağırlığı matrisi (W_{ij}) bulunur. Bu algoritma, alt seviyede bulunan kapsülün poz matrisinin, üst seviye kapsül poz matrisi için oy verme amacıyla, dönüşüm ağırlığı matrisi tarafından dönüştürülmesi prensibine göre çalışır [67].

$$V_{ij} = M_i W_{ij} \quad (3.23)$$

Tüm üst seviye katmanların pozları ve aktivasyonları, beklenti-maksimizasyon yönlendirme algoritmasına, V_{ij} ve a_i değerleri girilerek bulunur. Algoritma, üst seviye kapsülün varyans, ortalama ve aktivasyon olasılıkları ile alt ve üst seviye kapsüller

arasındaki atama olasılıklarını yinelemeli olarak günceller. Bu algoritmanın kullanılması, üst seviyedeki bütün kapsüllerin bir Gauss dağılımına, alt seviyedeki tüm aktif kapsül pozlarının ise bir veri noktasına karşılık gelmesine olanak sağlar [67].

Orijinal kapsül ağı modelinde ilk olarak, 3 giriş ve 256 çıkış kanalına, 9 kernel boyutuna ve 1 evrişim adımına (stride) sahip evrişim katmanı bulunmaktadır. Bu katmandan elde edilen çıktılar ReLU aktivasyon fonksiyonuna iletilmektedir. Daha sonra bu sonuçlar, 256 giriş ve 8 çıkış kanalına, 9 kernel boyutuna ve 2 evrişim adımına sahip 32 adet evrişim katmanı olan birincil kapsül katmanına gönderilmiştir. Son olarak, 3 kapsül ve 3 iterasyon sayısına sahip, aynı zamanda SoftMax fonksiyonu ile sınıflandırma işlemini gerçekleştiren ikincil kapsül katmanı ile model tamamlanmıştır (Şekil 3.14).



Şekil 3.14. Orijinal kapsül ağı mimarisi.


3.5. DİĞER YÖNTEMLER

Derin öğrenme alanında birçok farklı model öne sürülmüş ve kullanılmıştır. AlexNet, Alex Krizhevsky tarafından tasarlanan ve Ilya Sutskever ve Krizhevsky'nin doktora danışmanı Geoffrey Hinton ile yayınlanan evrişimsel bir ağıdır [31]. 30 Eylül 2012'de ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda yarışmış ve yüksek doğruluk oranı ile adını duyurmuştur. DenseNet, her katmanı ileri besleme tarzında diğer tüm katmanlara bağlayan Yoğun Evrişim Ağı olarak tanımlanır. Evrişimsel ağlarda girişe yakın katmanlar ve çıkışa yakın olanlar arasında daha kısa bağlantılar kurarak eğitimin daha derin, daha doğru ve verimli olmasını sağlar [82]. VGG, AlexNet'ten sonra katman sayısı artırılarak daha başarılı sonuçlar elde eden bir ağ yapısı olmuştur. VGG11, Simonyan ve Zisserman [83] tarafından tanıtılan 11 katmanlı bir evrişim

ağıdır. LeNet, 1998 yılında yayınlanmış olan evrişimli sinir ağı modelidir. Yann LeCun ve ekibi tarafından posta numaralarının, banka çekleri üzerindeki sayıların vb. okunması için geliştirilmiştir [84]. ResNet, çok yüksek sayıda eğitilebilir katman oluşturmaya olanak sağlayan bir artık ağıdır [85]. Çalışma prensibi serebral kortekste bulunan piramidal hücrelerin yapısına dayanır. ResNet bu işlemi, bazı katmanların üzerinden atlamak için kısayollar kullanarak yapar. Bu modeller, özellikle konuşma ve görüntü alanlarında birçok zorlu görevde başarılı sonuçlar elde etmekte ve sığ modellerden daha iyi performans göstermektedir [33, 86, 87].

3.6. GELİŞMİŞ KAPSÜL AĞI (ENHANCED CAPSULE NETWORK)

Orijinal kapsül mimarisinde kullanılan 9×9 kernel boyutuna sahip tek evrişim katmanı, giriş verilerinin derin özelliklerini yakalamak için yetersiz kalmaktadır. Bu dezavantajın üstesinden gelmek için tasarlanan gelişmiş kapsül ağı mimarisinde iki evrişim katmanı kullanılmıştır (Şekil 3.15). Birinci evrişim katmanı 3 giriş ve 256 çıkış kanalına, 5×5 kernel boyutuna ve 1 evrişim adımına sahipken, ikinci evrişim katmanı 256 giriş ve 256 çıkış kanalına, 5×5 çekirdek boyutuna ve 1 evrişim adımına sahiptir. Her iki katmanda da gelen çıktılar ReLU aktivasyon fonksiyonuna iletilmektedir. Birincil kapsül katmanında, her biri 256 giriş ve 8 çıkış kanallı 9×9 kernel boyutlu 2 evrişim adımına sahip 32 katman bulunmaktadır. Son olarak 3 kapsüllü, 3 iterasyonlu ve sınıflandırma işlemini SoftMax fonksiyonu ile gerçekleştiren ikincil kapsül katmanı ile model tamamlanmıştır [88].



Şekil 3.15. Gelişmiş kapsül ağı mimarisi.


BÖLÜM 4

DENEYSEL ÇALIŞMALAR

4.1. GELİŞMİŞ KAPSÜL AĞI İLE EEG TABANLI DUYGU TANIMA

Bu çalışmada, EEG verilerinden uygun kanalların seçilmesini, seçilen kanalların Welch güç spektral yoğunluk tahmini ile özelliklerinin çıkarımını ve gelişmiş kapsül ağı tabanlı sınıflandırma modelini içeren bir yöntem sunulmaktadır. Seed EEG veri seti ile elde edilen sonuçlar ayrıca diğer son teknoloji yöntemlerle karşılaştırılarak değerlendirilmiştir. Son olarak önerilen yöntem Dreamer ve Deep EEG veri setleri ile test edilmiştir.


4.1.1. Ön İşleme



Şekil 4.1. Tek bir uygulamadan elde edilen EEG kaydı.


Bu çalışmada kullanılan SEED veri setinde bulunan EEG verileri 200 Hz örnekleme hızına düşürülmüştür. Gürültüyü filtrelemek için EEG verileri 0.3 ile 50 Hz arasında bant geçiren filtre ile işlenmiştir. Deneylerde elde edilen Elektrookülografi (EOG)

verisi kaydedilen EEG verilerinden göz kırpmaya artefaktlarını tespit etmek için kullanılmıştır. Ön işlem yapıldıktan sonra her filmin süresine karşılık gelen EEG segmentleri çıkarılmış ve elde edilen EEG verilerinin her kanalı aynı uzunlukta periyotlara bölünmüştür [9] (Şekil 4.2).



Şekil 4.2. Tek kanal (FP₁) EEG kaydı.

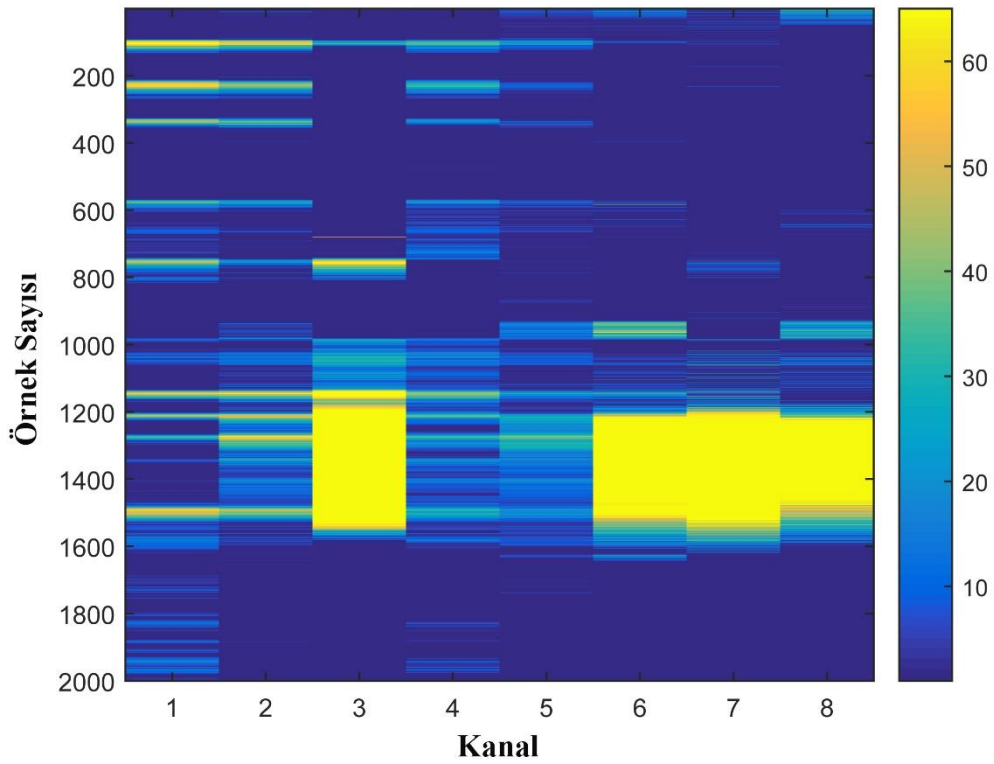
Ön işlemden sonra her bir uygulamadan elde edilen EEG verileri 2000 örnek sayısından oluşan alanlara ayrıldı (Şekil 4.3).



Şekil 4.3. (62 x 2000) Ham EEG verisinin görselleştirilmiş hali.

4.1.2. Kanal Seçimi


Kanal seçimi işleminde, duygusal bir uyarılma sırasında beynin en çok etkilendiği bölgelerin tespit edilmesi ve o bölgelere ait kanalların tercih edilmesi oldukça önemli bir konudur. Bu çalışmada Seed EEG verilerindeki 62 kanal içerisinde AF3, AF4, F3, F4, F7, F8, T7 ve T8 olmak üzere sekiz elektrotlu bir havuz elde edildi [14]. Her bir kanal için 2000 adet örnek sayısı alındı. Böylece, 8 kanal ve her bir kanal için 2000 örnek sayısına sahip (8 x 2000) girdi matrisleri elde edildi (Şekil 4.4).




Şekil 4.4. (8 x 2000) Ham EEG verisinin görselleştirilmiş hali.

4.1.3. Özellik Çıkarma

Girdi matrisindeki sekiz kanalın, 5. Ayrışma seviyesinde ayrık dalgacık dönüşümü ve Welch güç spectral yoğunluğu tahmini yöntemleri ile özellikleri çıkarıldı. Ardından RGB formatında (3 kanal) görsel hale getirildi. Şekil 4.5, Ayrık dalgacık dönüşümü ile özellik çıkarma işlemini, Şekil 4.6 ise Welch güç spectral yoğunluğu tahmini ile özellik çıkarma işlemini göstermektedir.



Şekil 4.5. Ayrık dalgacık dönüşümü ile özellik çıkarma işlemi.



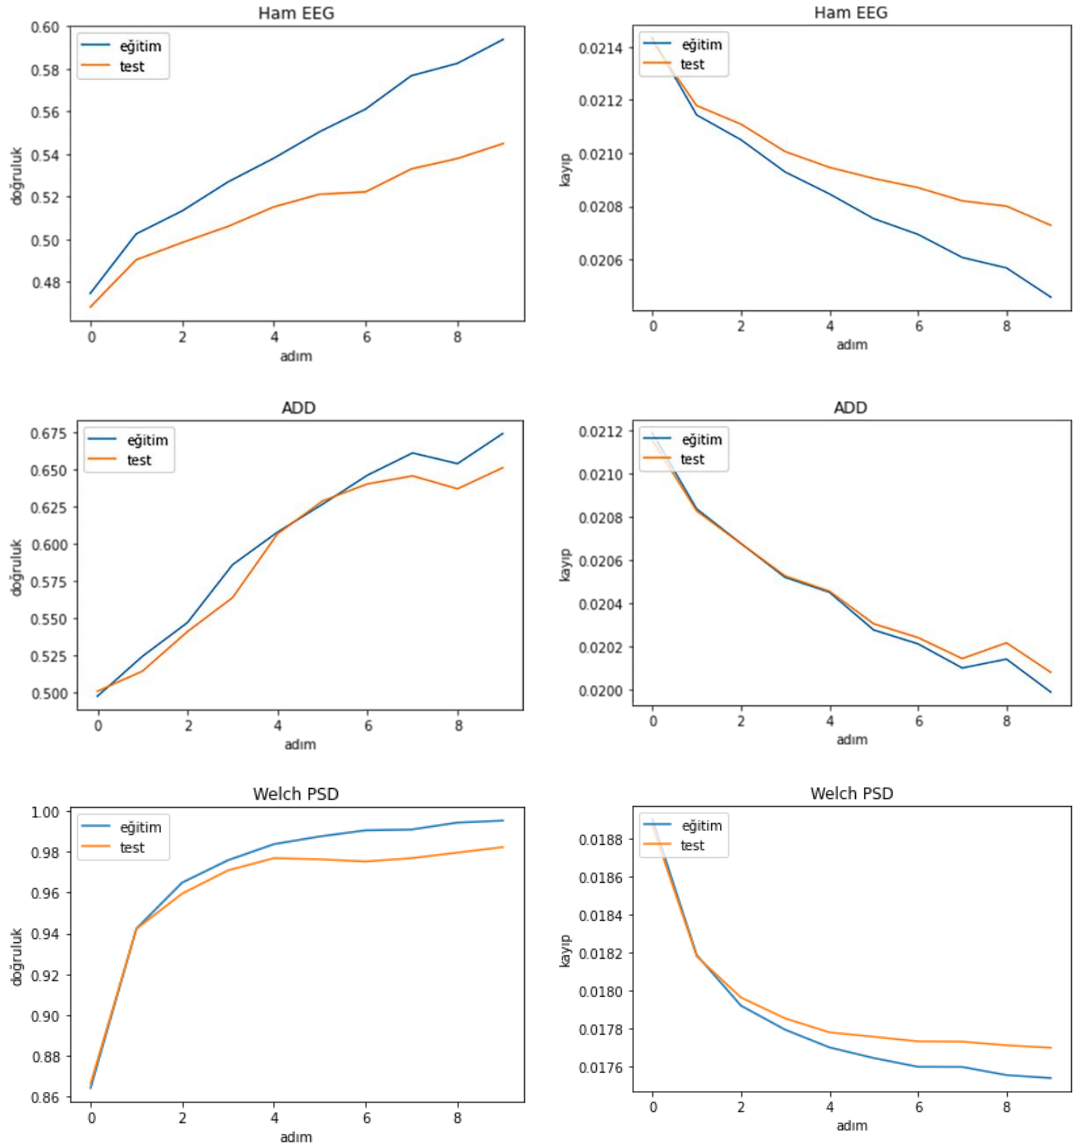
Şekil 4.6. Welch güç spektral yoğunluğu tahmini ile özellik çıkarma işlemi.

4.1.4. Verilerin Hazırlanması

Özellik çıkarma işleminden sonra resimlerin temsil ettiği duygular (negatif, pozitif ve nötr) sırasıyla 0, 1 ve 2 değerleri ile etiketlendi. Bu işlemler sonunda sınıflandırma modellerinde kullanmak için üç ayrı veriseti ($14850 \times 3 \times 64 \times 64$) elde edildi. Birinci verisetinde, hiçbir özellik çıkarma işlemi yapılmadan sadece ön işlemden geçmiş ve uygun kanalları seçilmiş ham EEG verisi, İkinci verisetinde bu işlemlerin yanında, 5. Ayrışma seviyesinde ayrık dalgacık dönüşümü (ADD) ile özellikleri çıkarılan EEG verisi, üçüncü verisetinde ise Welch güç spektral yoğunluğu tahmini (Welch PSD) kullanılarak özellikleri çıkarılan EEG verisi kullanıldı.

4.1.5. Deneysel Sonular

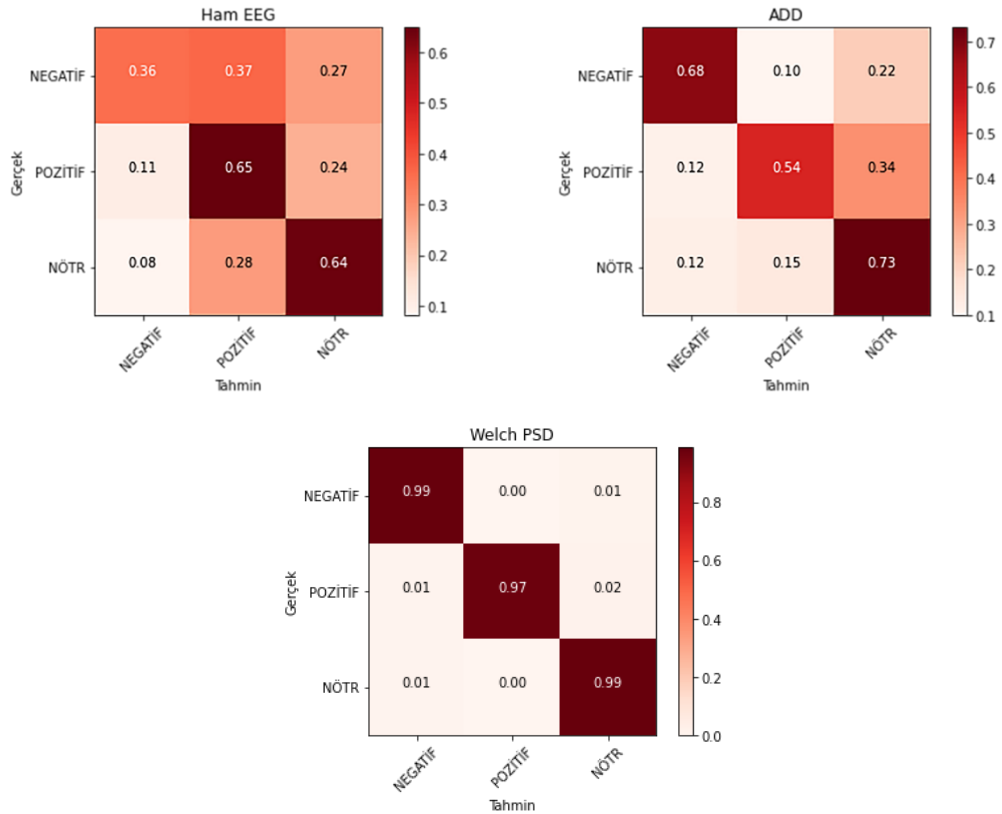
Bu blm, nerilen erevenin mevcut birkaç yntem arasındaki karşılařtırımlı dođruluk ve verimlilik sonularını sunar. Őekil 4.7’de, elde edilen  veri seti kullanılarak geliřmiř kapsl ađı tabanlı model ile yapılan sınıflandırma sonucunda alınan dođruluk ve kayıp grafikleri karşılařtırımlı olarak verilmektedir.



Őekil 4.7. Modelin dođruluk ve kayıp grafikleri.

Grldđ zere hibir zellik ıkarma iřlemi yapılmadan sadece n iřlemden gemiř ve uygun kanalları seilmiř ham EEG verisi ile yapılan sınıflandırma iřlemi en dřk dođruluk oranını (%59.37 eđitim, %54.48 test) vermiřtir. Aynı zamanda eđitim ve test

sonucu alınan doğruluk değerleri arasındaki fark diğer uygulamalara göre daha yüksektir. EEG verisinin hiçbir özellik çıkarma işlemine tabi tutulmadan (ham veri olarak) görüntü formatına dönüştürülmesi, elde edilen resmin oldukça karmaşık olmasına neden olmaktadır. Bu durum modelin doğruluk ve verimlilik sonuçlarını olumsuz yönde etkilemektedir. Öte yandan bu işlemlerin yanında, 5. ayrışma seviyesinde ayırık dalgacık dönüşümü kullanılarak özellikleri çıkarılan EEG verisi ile yapılan sınıflandırma işleminde hem doğruluk oranı artmış (%67.36 eğitim, %65.08 test) hem de eğitim ve test sonucu alınan doğruluk değerleri arasındaki fark azalmıştır. Son olarak Welch güç spektral yoğunluğu tahmini kullanılarak özellikleri çıkarılan EEG verisi ile yapılan sınıflandırma işleminde ise doğruluk oranı en yüksek değere çıkarken (%99.51 eğitim, %98.21 test) eğitim ve test sonucu alınan doğruluk değerleri arasındaki fark en aza inmiştir. Makine öğrenmesinde sınıflandırma modellerinin performansını ölçmek için genellikle karmaşıklık matrisi ve sınıflandırma metrikleri kullanılır. Elde edilen üç veri seti kullanılarak, gelişmiş kapsül ağı tabanlı model ile yapılan sınıflandırma sonucunda alınan karmaşıklık matrisleri (Şekil 4.8) ve sınıflandırma metrikleri (Çizelge 4.1) karşılaştırmalı olarak verilmektedir.



Şekil 4.8. Modelin karmaşıklık matrisleri.

Çizelge 4.1. Modelin sınıflandırma metrikleri.

		Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	Ham EEG	0.67	0.49	0.55	0.57
	ADD	0.75	0.69	0.55	0.67
	Welch PSD	0.98	1.00	0.97	0.98
Duyarlılık	Ham EEG	0.36	0.65	0.64	0.54
	ADD	0.68	0.54	0.73	0.65
	Welch PSD	0.99	0.97	0.99	0.98
F1-Skoru	Ham EEG	0.46	0.56	0.59	0.54
	ADD	0.71	0.61	0.63	0.65
	Welch PSD	0.98	0.99	0.98	0.98
Örnek Sayısı	Ham EEG	641	600	609	1850
	ADD	631	622	597	1850
	Welch PSD	603	638	609	1850

Alınan sonuçlara göre en yüksek doğruluk oranını veren (Welch PSD) veri seti kullanılarak kapsül ağ tabanlı sınıflandırma modeli ile CNN, Alexnet, DenseNet, VGG11, LeNet ve ResNet modellerinin doğruluk ve verimlilik sonuçları (Çizelge 4.2) karşılaştırılmıştır.

Çalışmada kullanılan CNN modelinde sırasıyla, 32 ve 64 filtre sayısına ve 3×3 filtre boyutuna sahip iki adet evrişim katmanı bulunmaktadır. Bu katmanları 3×3 boyutundaki kümelerden en büyük değerleri alarak yeni bir matris oluşturan ortaklama (MaxPooling) katmanı takip etmektedir. Modeldeki aşırı öğrenmeyi (overfitting) önlemek için 0.5 oranında seyreltme (dropout) katmanı kullanılmıştır. Son kısımda sırasıyla, 250 ve 3 nörondan oluşan iki adet yapay sinir ağı katmanı (dense) bulunmaktadır.

LeNet modelinde ilk katmanda, 6 filtre sayısına ve 5×5 filtre boyutuna sahip evrişim katmanı bulunur. İkinci katman, 6 adet 14×14 boyutunda özellik grafiği veren ortaklama katmanıdır. Üçüncü katmanda, 16 filtre sayısına ve 5×5 filtre boyutuna sahip evrişim katmanı bulunur. Dördüncü katman, 16 adet 5×5 boyutunda özellik grafiği veren ortaklama katmanıdır. Beşinci katman, 5×5 boyutunda 120 filtre sayısına sahip evrişim katmanıdır. Altıncı katman ise beşinci katmandan aldığı girdi ile 84 adet özellik grafiği çıkaran tam bağlantı (fully connected) katmanıdır.

AlexNet, DenseNet, VGG11 ve ResNet modelleri, ImageNet veritabanında bir milyondan fazla görüntü ile önceden eğitilen ve sırasıyla 8, 121, 11 ve 18 katman derinliklerine sahip evrişimli sinir ağlarıdır.

Çizelge 4.2. Elde edilen doğruluk ve verimlilik sonuçları.

	Adım	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru
CNN	10	%92.71	%92.70	%92.71	%92.70
AlexNet	10	%95.08	%95.13	%95.06	%95.08
DenseNet	10	%92.68	%92.68	%92.71	%92.69
VGG11	10	%95.09	%95.08	%95.09	%95.08
LeNet	10	%95.21	%95.36	%95.23	%95.22
ResNet	10	%94.59	%94.59	%94.58	%94.58
Orijinal Kapsül Ağı	10	%97.35	%97.34	%97.35	%94.34
Gelişmiş Kapsül Ağı	10	%98.21	%98.21	%98.20	%98.20

Son olarak önerilen yöntem Dreamer ve Deap veri setleri ile test edilmiştir. Dreamer veri seti 18 film klibini izleyen 23 denekten (14 erkek, 9 kadın) 14 elektrotlu bir cihaz ile alınan EEG verilerini içerir [52]. Bu veri setinde EEG sinyalleri 128 Hz örnekleme hızı ile kaydedilmiş ve Hamming sinc linear phase FIR ile filtrelenmiştir [51].

Deap veri setinde 32 denek 40 adet birer dakikalık müzik videosu izlemişlerdir. Her bir denekten 32 kanal EEG verisi ve 8 kanal fizyolojik sinyal verisi elde edilmiştir. Bu çalışmada Deap veri setinin ön işleminden geçmiş bir versiyonu kullanılmıştır [53].

Çizelge 4.3. Dreamer ve Deap veri setinden elde edilen doğruluk değerleri.

		Değerlik	Uyarılma	Baskınlık
Dreamer	Orijinal Kapsül Ağı	%92.20	%93.15	%93.10
	Gelişmiş Kapsül Ağı	%94.25	%95.30	%95.20
Deap	Orijinal Kapsül Ağı	%96.10	%97.50	%97.25
	Gelişmiş Kapsül Ağı	%97.90	%98.70	%98.55

Sonuçlara bakıldığında gelişmiş kapsül ağı modelinin, Dreamer ve Deap veri setlerinde de başarılı sonuçlar verdiği görülmektedir.

4.2. DERİN EEG SINIFLANDIRMADA METASEZGİSEL YÖNTEMLER

İnsan beyninden farklı kanal problemleri ile veri toplamanın zorluğunun yanı sıra, verilerin ön işlenmesi, daha iyi bir başarı elde etmek için çözülmesi gereken farklı ve önemli bir görevdir. En aktif kanalların seçimi, yüksek sınıflandırma doğruluğu elde etmek için önemli bir problemdir. Kanal seçimi problemini çözmek için iki farklı yaklaşım vardır, birincisi verilerden bilgi çıkarmak ve ikincisi seçilen kanal alt kümesini değerlendirmektir. Metasezgiseller, makul bir sürede kabul edilebilir bir çözüm elde etme kabiliyetine sahip olduklarından, orijinal kümeden optimal alt kümeyi seçmek için iyi çözümlerdir. Ayrıca duyu tanıma için kullanılan geleneksel derin öğrenme yöntemleri, EEG sinyallerinin uzamsal özelliklerini göz ardı etmektedir. Bu, sınıflandırma doğruluğunu azaltır. Bu çalışmada, sınıflandırma doğruluğunu artırmak için Seed veri seti üzerinde yapay arı kolonisi optimizasyon algoritması kullanıldı. Bu algoritmanın dört farklı varyasyonu uygulandı ve test edildi. Gelişmiş kapsül ağı, bir makine öğrenme algoritması olarak kullanıldı ve sorunu çözmek için en iyi yapılandırma gösterildi.


4.2.1. Metasezgisel Yöntemler İle Kanal Seçimi

Bu bölümde kanal seçimi için uygulanan deneysel çalışmalar ve bu çalışmalardan elde edilen bulgular paylaşılmaktadır. 62 kanal içeren veri kümesi üzerinde dört farklı ABC varyasyonu en yüksek başarıya ulaşmak amacıyla test edildi. Uygulama Python programlama dili ile gerçekleştirildi. Kanal seçim çalışmaları, 32 GB ram içeren bilgisayar ve Windows 10 işletim sistemi üzerinde çalıştırıldı. Tüm algoritmalar 2000 MaxFE ve 40 popülasyonlu ABC için uygulandı. Tüm yöntemler için elde edilen sonuçlar Çizelge 4.4'te verilmiştir. Çizelgede görüleceği üzere en iyi sonuç, 0.992 doğruluk değeri ile NBABC algoritmasına aittir. BinABC ve iBinABC aynı en yüksek başarı değerine ulaşırken ortalama başarıya göre iBinABC daha iyi bir sonuç sunmaktadır. NBABC ise standart sapma hariç tüm metrikler açısından en iyi performansı vermektedir. Çizelgedeki sonuçlara göre en düşük performans gösteren yöntem ise DisABC olduğu görülmektedir.

Çizelge 4.4. Kanal seçim sonuçları.

	En İyi	Ortalama	En Kötü	Standart Sapma
BinABC	0.9866	0.9820	0.9786	0.0025
DisABC	0.9833	0.9807	0.9756	0.0021
iBinABC	0.9886	0.9870	0.9850	0.0012
NBABC	0.9920	0.9901	0.9876	0.0013


Tüm yöntemlerden, en yüksek başarıya ait uygulama için elde edilen kanallar Şekil 4.9'da görselleştirilmiştir. Buna göre 18, 21, 41, 43, 45, 48, 49, 50, 54, 56 numaralı kanallar tüm yöntemler tarafından seçilmektedir. 1, 3, 9, 10, 23, 27, 30, 46 ve 60 numaralı kanallar sadece DisABC ile seçilirken, 17 ve 25 numaralı kanallar sadece iBinABC ile, 13, 31, 38, 57 ve 58 numaralı kanallar ise sadece BinABC ile seçilmektedir. Sadece NBABC ile seçilen ise 34 numaralı kanaldır.



Şekil 4.9. Dört algoritma ile seçilen kanallar.

4.2.2. Özellik Çıkarma


EEG verisinden elde edilen kanallar 2000 örnek sayısına sahip alanlara bölündü. Her bir alanın Welch PSD yöntemi ile özellikleri çıkarıldı ve görsel hale getirildi. Şekil 4.10, elde edilen kanallara ait ölçüm verilerinin Welch PSD yöntemi ile özellikleri çıkarıldıktan sonra görsel hale getirilme sürecini gösterirken aynı zamanda özellik çıkarma işlemi yapılmamış veri ile olan farklılıkları göstermektedir. Şekilde görüldüğü üzere özellik çıkarma işlemi verilerin daha sağlam ve tutarlı şekilde temsil edilmesini sağlamıştır.



Şekil 4.10. Welch PSD yöntemi ile özellik çıkarma işlemi.

4.2.3. Verilerin Hazırlanması

Yapılan işlemler sonucunda, her bir yöneme ait $14850 \times 3 \times 64 \times 64$ boyutunda veri setleri elde edildi. Şekil 4.11’de her bir veri setine ait girdi örnekleri yer almaktadır.




Şekil 4.11. Elde edilen veri setlerinden girdi örnekleri.

4.2.4. Deneysel Sonuçlar


Elde edilen veri setleri orijinal kapsül ağı ve gelişmiş kapsül ağı ile sınıflandırıldı. Çalışmada kullanılan gelişmiş kapsül ağı modelinde, daha derin özelliklerin tespit edilebilmesi için orijinal kapsül mimarisinde kullanılan tek evrişim katmanı yerine iki evrişim katmanı kullanıldı. Birinci evrişim katmanında, 3 giriş ve 256 çıkış kanalı, 5×5 kernel boyutu ve 1 evrişim adımı kullanıldı. İkinci evrişim katmanında ise 256 giriş ve 256 çıkış kanalı, 5×5 kernel boyutu ve 1 evrişim adımı kullanıldı. Her iki katmanda, gelen çıktılar ReLU fonksiyonuna gönderildi. Birincil kapsül katmanında, her biri 256 giriş ve 8 çıkış kanalı, 9×9 kernel boyutu ve 2 evrişim adımı olan 32 adet katman bulunmaktadır. Son olarak 3 kapsül ve 3 iterasyon sayısına sahip, sınıflandırma işlemini SoftMax fonksiyonu ile gerçekleştiren ikincil kapsül katmanı ile model tamamlanmıştır. Bu bölümde kanal seçiminde kullanılan her bir yöntem ile elde edilen verilerin sınıflandırma sonucundaki performans ve verimlilik değerleri ilgili başlık altında verilmektedir.

4.2.4.1. BinABC Algoritma Sonuçları

Bu bölümde BinABC algoritması kullanılarak seçilen kanallar ile oluşturulan veri setinin orijinal kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırma sonucunda elde edilen performans ve verimlilik sonuçları yer almaktadır. 18, 21, 41, 43, 45, 48, 49, 50, 54, 56 numaralı kanallar tüm yöntemler tarafından seçilmektedir. Sadece BinABC algoritması ile seçilen kanallar ise 13, 31, 38, 57 ve 58 numaralı kanallardır. Şekil 4.12, orijinal kapsül ağı ve gelişmiş kapsül ağındaki her bir adımda elde edilen doğruluk değerlerini, Şekil 4.13 ise yine aynı ağların kayıp değerlerini vermektedir.



Şekil 4.12. BinABC algoritması ile elde edilen doğruluk grafiği.



Şekil 4.13. BinABC algoritması ile elde edilen kayıp grafiği.

Çizelge 4.5, orijinal kapsül ağı ve gelişmiş kapsül ağındaki eğitim ve test sonucu alınan doğruluk ve kayıp değerlerini, Çizelge 4.6 ise yine aynı ağlardan elde edilen sınıflandırma metriklerini karşılaştırmalı olarak vermektedir.

Çizelge 4.5. BinABC algoritması ile elde edilen doğruluk ve kayıp değerleri.

	Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
Doğruluk (Eğitim)	0.9893	0.9998
Doğruluk (Test)	0.9856	0.9960
Kayıp (Eğitim)	0.0174	0.0174
Kayıp (Test)	0.0175	0.0175


Çizelge 4.6. BinABC algoritması ile elde edilen sınıflandırma metrikleri.

	Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
	Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	0.99	0.98	0.99	0.99	1.00	1.00	1.00	1.00
Duyarlılık	0.98	0.98	0.99	0.99	0.99	1.00	1.00	1.00
F1-Skoru	0.98	0.98	0.99	0.99	0.99	1.00	1.00	1.00
Örnek Sayısı	1590	1648	1612	4850	1590	1648	1612	4850


4.2.4.2. DisABC Algoritma Sonuçları

Bu bölümde DisABC algoritması kullanılarak seçilen kanallar ile oluşturulan veri setinin orijinal kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırma sonucunda elde edilen performans ve verimlilik sonuçları yer almaktadır. 18, 21, 41, 43, 45, 48, 49, 50, 54, 56 numaralı kanallar tüm yöntemler tarafından seçilmektedir. Sadece DisABC algoritması ile seçilen kanallar ise 1, 3, 9, 10, 23, 27, 30, 46 ve 60 numaralı

kanallardır. Şekil 4.14, orijinal kapsül ağı ve gelişmiş kapsül ağındaki her bir adımda elde edilen doğruluk değerlerini, Şekil 4.15 ise yine aynı ağların her bir adımda elde edilen kayıp değerlerini karşılaştırmalı olarak vermektedir.



Şekil 4.14. DisABC algoritması ile elde edilen doğruluk grafiği.



Şekil 4.15. DisABC algoritması ile elde edilen kayıp grafiği.

Çizelge 4.7, orijinal kapsül ağı ve gelişmiş kapsül ağındaki eğitim ve test sonucu alınan doğruluk ve kayıp değerlerini, Çizelge 4.8 ise yine aynı ağlardan elde edilen sınıflandırma metriklerini karşılaştırmalı olarak vermektedir.

Çizelge 4.7. DisABC algoritması ile elde edilen doğruluk ve kayıp değerleri.


	Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
Doğruluk (Eğitim)	0.9893	0.9998
Doğruluk (Test)	0.9881	0.9983
Kayıp (Eğitim)	0.0174	0.0174
Kayıp (Test)	0.0175	0.0175

Çizelge 4.8. DisABC algoritması ile elde edilen sınıflandırma metrikleri.


	Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
	Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00
Duyarlılık	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00
F1-Skoru	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00
Örnek Sayısı	1577	1647	1626	4850	1577	1647	1626	4850

4.2.4.3. iBinABC Algoritma Sonuçları

Bu bölümde iBinABC algoritması kullanılarak seçilen kanallar ile oluşturulan veri setinin orijinal kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırma sonucunda elde edilen performans ve verimlilik sonuçları yer almaktadır. 18, 21, 41, 43, 45, 48, 49, 50, 54, 56 numaralı kanallar tüm yöntemler tarafından seçilmektedir. Sadece iBinABC algoritması ile seçilen kanallar ise 17 ve 25 numaralı kanallardır. Şekil 4.16, orijinal kapsül ağı ve gelişmiş kapsül ağındaki her bir adımda elde edilen doğruluk değerlerini, Şekil 4.17 ise yine aynı ağların kayıp değerlerini vermektedir.



Şekil 4.16. iBinABC algoritması ile elde edilen doğruluk grafiği.



Şekil 4.17. iBinABC algoritması ile elde edilen kayıp grafiği.

Çizelge 4.9, orijinal kapsül ağı ve gelişmiş kapsül ağındaki eğitim ve test sonucu alınan doğruluk ve kayıp değerlerini, Çizelge 4.10 ise yine aynı ağlardan elde edilen sınıflandırma metriklerini karşılaştırmalı olarak vermektedir.

Çizelge 4.9. iBinABC algoritması ile elde edilen doğruluk ve kayıp değerleri.


	Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
Doğruluk (Eğitim)	0.9893	0.9998
Doğruluk (Test)	0.9829	0.9958
Kayıp (Eğitim)	0.0174	0.0174
Kayıp (Test)	0.0175	0.0175

Çizelge 4.10. iBinABC algoritması ile elde edilen sınıflandırma metrikleri.

	Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
	Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	0.98	0.98	0.98	0.98	1.00	0.99	1.00	1.00
Duyarlılık	0.98	0.98	0.98	0.98	0.99	1.00	1.00	1.00
F1-Skoru	0.98	0.98	0.98	0.98	1.00	1.00	1.00	1.00
Örnek Sayısı	1670	1587	1593	4850	1670	1587	1593	4850


4.2.4.4. NBABC Algoritma Sonuçları

Bu bölümde NBABC algoritması kullanılarak seçilen kanallar ile oluşturulan veri setinin orijinal kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırma sonucunda elde edilen performans ve verimlilik sonuçları yer almaktadır. 18, 21, 41, 43, 45, 48, 49, 50, 54, 56 numaralı kanallar tüm yöntemler tarafından seçilmektedir. Sadece iBinABC algoritması ile seçilen kanal 34 numaralı kanaldır.



Şekil 4.18. NBABC algoritması ile elde edilen doğruluk grafiği.

Şekil 4.18, orijinal kapsül ağı ve gelişmiş kapsül ağındaki her bir adımda elde edilen doğruluk değerlerini, Şekil 4.19 ise yine aynı ağların her bir adımda elde edilen kayıp değerlerini karşılaştırmalı olarak vermektedir.



Şekil 4.19. NBABC algoritması ile elde edilen kayıp grafiği.

Çizelge 4.11, orijinal kapsül ağı ve gelişmiş kapsül ağındaki eğitim ve test sonucu alınan doğruluk ve kayıp değerlerini, Çizelge 4.12 ise yine aynı ağlardan elde edilen sınıflandırma metriklerini karşılaştırmalı olarak vermektedir.

Çizelge 4.11. NBABC algoritması ile elde edilen doğruluk ve kayıp değerleri.

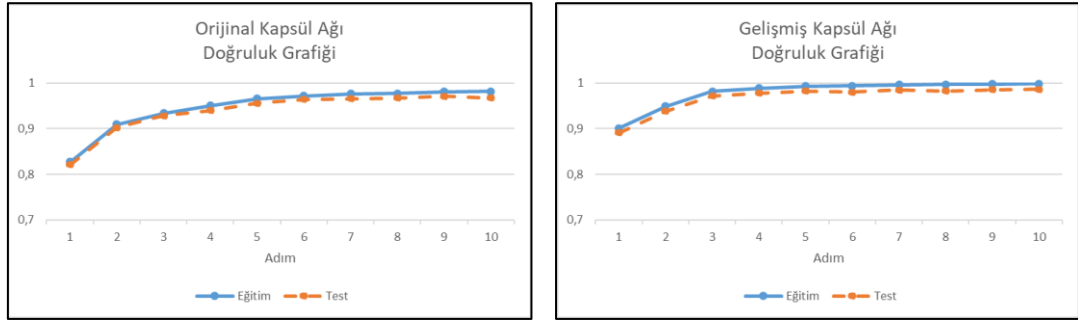
	Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
Doğruluk (Eğitim)	0.9891	0.9996
Doğruluk (Test)	0.9809	0.9936
Kayıp (Eğitim)	0.0174	0.0174
Kayıp (Test)	0.0175	0.0175

Çizelge 4.12. NBABC algoritması ile elde edilen sınıflandırma metrikleri.


	Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
	Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	0.98	0.99	0.98	0.98	0.99	1.00	0.99	0.99
Duyarlılık	0.98	0.98	0.99	0.98	0.99	0.99	1.00	0.99
F1-Skoru	0.98	0.98	0.98	0.98	0.99	0.99	0.99	0.99
Örnek Sayısı	1636	1630	1584	4850	1636	1630	1584	4850

4.2.4.5. Ortak Kanallar

Bu bölümde ABC algoritmasında bulunan bütün varyasyonlardan seçilen ortak kanallar ile oluşturulan veri setinin orijinal kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırma sonucunda elde edilen performans ve verimlilik sonuçları yer almaktadır. 18, 21, 41, 43, 45, 48, 49, 50, 54, 56 numaralı kanallar tüm yöntemler tarafından seçilmektedir. Şekil 4.20, orijinal kapsül ağı ve gelişmiş kapsül ağındaki her bir adımda elde edilen doğruluk değerlerini, Şekil 4.21 ise yine aynı ağların her bir adımında elde edilen kayıp değerlerini karşılaştırmalı olarak vermektedir.



Şekil 4.20. Ortak kanallar ile elde edilen doğruluk grafiği.



Şekil 4.21. Ortak kanallar ile elde edilen kayıp grafiği.

Çizelge 4.13, orijinal kapsül ağı ve gelişmiş kapsül ağındaki eğitim ve test sonucu alınan doğruluk ve kayıp değerlerini, Çizelge 4.14 ise yine aynı ağlardan elde edilen sınıflandırma metriklerini karşılaştırmalı olarak vermektedir.

Çizelge 4.13. Ortak kanallar ile elde edilen doğruluk ve kayıp değerleri.

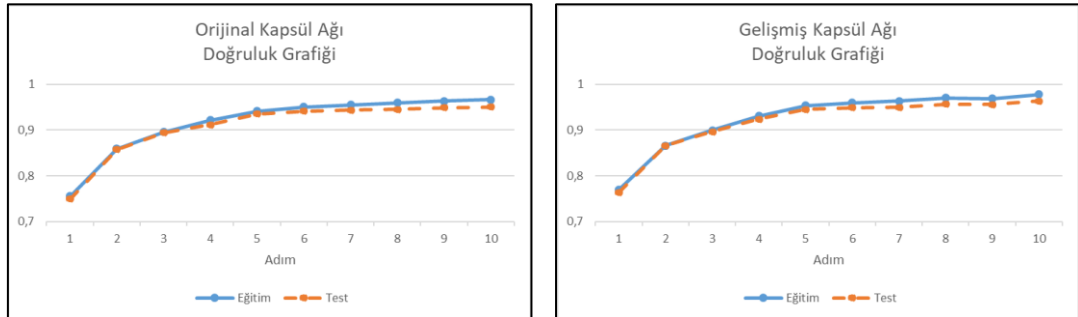
	Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
Doğruluk (Eğitim)	0.9818	0.9981
Doğruluk (Test)	0.9675	0.9859
Kayıp (Eğitim)	0.0176	0.0175
Kayıp (Test)	0.0177	0.0176

Çizelge 4.14. Ortak kanallar ile elde edilen sınıflandırma metrikleri.


	Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
	Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	0.96	0.98	0.95	0.97	0.98	0.99	0.99	0.99
Duyarlılık	0.97	0.95	0.98	0.97	0.99	0.98	0.99	0.99
F1-Skoru	0.97	0.97	0.97	0.97	0.99	0.99	0.99	0.99
Örnek Sayısı	1616	1621	1613	4850	1616	1621	1613	4850

4.2.4.6. Tüm Kanallar

Bu bölümde Seed EEG veri tabanında bulunan 62 kanalın tamamı ile oluşturulan veri setinin original kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırma sonucunda elde edilen performans ve verimlilik sonuçları yer almaktadır. Şekil 4.22, orijinal kapsül ağı ve gelişmiş kapsül ağındaki her bir adımda elde edilen doğruluk değerlerini, Şekil 4.23 ise yine aynı ağların her bir adımda elde edilen kayıp değerlerini karşılaştırmalı olarak vermektedir.



Şekil 4.22. Tüm kanallar ile elde edilen doğruluk grafiği.



Şekil 4.23. Tüm kanallar ile elde edilen kayıp grafiği.

Çizelge 4.15, orijinal kapsül ağı ve gelişmiş kapsül ağındaki eğitim ve test sonucu alınan doğruluk ve kayıp değerlerini, Çizelge 4.16 ise yine aynı ağlardan elde edilen sınıflandırma metriklerini karşılaştırmalı olarak vermektedir.

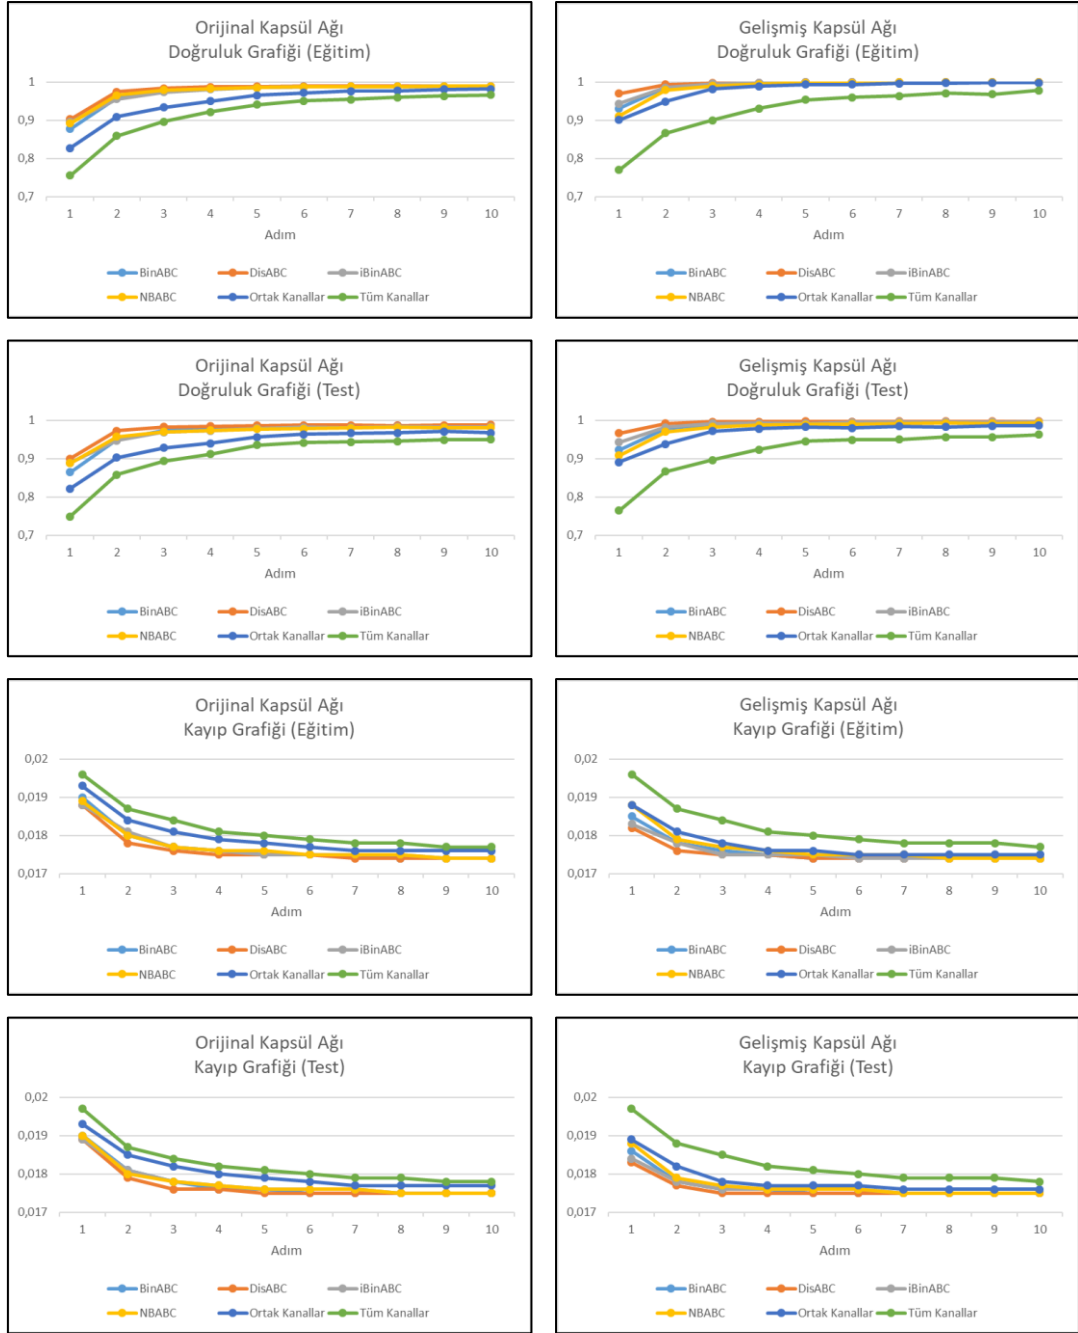
Çizelge 4.15. Tüm kanallar ile elde edilen doğruluk ve kayıp değerleri.

	Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
Doğruluk (Eğitim)	0.9661	0.9778
Doğruluk (Test)	0.9502	0.9630
Kayıp (Eğitim)	0.0177	0.0177
Kayıp (Test)	0.0178	0.0178

Çizelge 4.16. Tüm kanallar ile elde edilen sınıflandırma metrikleri.

	Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
	Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
Kesinlik	0.94	0.94	0.97	0.95	0.96	0.95	0.98	0.96
Duyarlılık	0.97	0.96	0.93	0.95	0.98	0.97	0.94	0.96
F1-Skoru	0.95	0.95	0.95	0.95	0.97	0.96	0.96	0.96
Örnek Sayısı	1617	1599	1634	4850	1617	1599	1634	4850

Şekil 4.24, alınan tüm sonuçların tek bir seferde görülebilmesi için orijinal kapsül ağı ve gelişmiş kapsül ağı ile yapılan sınıflandırmaların her bir adımda ulaştığı doğruluk ve kayıp değerini karşılaştırmalı olarak vermektedir.



Şekil 4.24. Doğruluk ve kayıp değerleri.

Çizelge 4.17, alınan tüm sonuçların tek bir seferde görülebilmesi için kanal seçiminde kullanılan her bir yöntemin bulduğu kritik kanal sayısını ve bu kanallar ile elde edilen verilerin sınıflandırma sonucundaki doğruluk değerlerini karşılaştırmalı olarak vermektedir.

Çizelge 4.17. Sınıflandırma sonuçları.

Yöntem	Kanal Sayısı	Özellik Çıkarma		Orijinal Kapsül Ağı	Gelişmiş Kapsül Ağı
DisABC	36	Welch PSD	Doğruluk (Eğitim)	0.9893	0.9998
			Doğruluk (Test)	0.9881	0.9983
			Kayıp (Eğitim)	0.0174	0.0174
			Kayıp (Test)	0.0175	0.0175
BinABC	28	Welch PSD	Doğruluk (Eğitim)	0.9893	0.9998
			Doğruluk (Test)	0.9856	0.9960
			Kayıp (Eğitim)	0.0174	0.0174
			Kayıp (Test)	0.0175	0.0175
iBinABC	25	Welch PSD	Doğruluk (Eğitim)	0.9893	0.9998
			Doğruluk (Test)	0.9829	0.9958
			Kayıp (Eğitim)	0.0174	0.0174
			Kayıp (Test)	0.0175	0.0175
NBABC	25	Welch PSD	Doğruluk (Eğitim)	0.9891	0.9996
			Doğruluk (Test)	0.9809	0.9936
			Kayıp (Eğitim)	0.0174	0.0174
			Kayıp (Test)	0.0175	0.0175
Ortak Kanallar	10	Welch PSD	Doğruluk (Eğitim)	0.9818	0.9981
			Doğruluk (Test)	0.9675	0.9859
			Kayıp (Eğitim)	0.0176	0.0175
			Kayıp (Test)	0.0177	0.0176
Tüm Kanallar	62	Welch PSD	Doğruluk (Eğitim)	0.9661	0.9778
			Doğruluk (Test)	0.9502	0.9630
			Kayıp (Eğitim)	0.0177	0.0177
			Kayıp (Test)	0.0178	0.0178

Elde edilen sonuçlara göre DisABC algoritması ile EEG sinyallerinden uygun kanalların seçimine, Welch güç spektral yoğunluğu tahmini ile özellik çıkarma işlemine ve gelişmiş kapsül ağı dayanan yöntemin, diğer yöntemlere göre daha yüksek doğruluk değerlerine (%99.98 eğitim, %99.83 test) ulaştığı tespit edilmiştir. DisABC algoritması 62 kanal içerisinde en kritik 36 kanalı tespit ederek yüksek doğruluk oranına ulaşmak için en büyük katkıyı sağlamıştır. Welch PSD özellik çıkarma yöntemi sayesinde elde edilen bu 36 kanal en az kayıpla ve en sade şekilde temsil edilmiş ve görsel hale getirilmiştir. Ayrıca gelişmiş kapsül ağındaki evrişim katmanı ikiye çıkarılıp kernel boyutu düşürüldüğü için görüntülerdeki daha derin özelliklerin

tespit edilebilmesi sağlanmıştır. Çizelge 4.18 ise ağın sınıflandırma performansının ölçülebilmesi için her bir duygu sınıfına (Negatif, Pozitif ve Nötr) ait kesinlik, duyarlılık ve f1-skoru değerlerini karşılaştırmalı olarak vermektedir.

Çizelge 4.18. Sınıflandırma metrikleri.

		Orijinal Kapsül Ağı				Gelişmiş Kapsül Ağı			
		Negatif	Pozitif	Nötr	Ağırlıklı Ort.	Negatif	Pozitif	Nötr	Ağırlıklı Ort.
DisABC	Kesinlik	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00
	Duyarlılık	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00
	F1-Skoru	0.99	0.99	0.99	0.99	1.00	1.00	1.00	1.00
	Örnek Sayısı	1577	1647	1626	4850	1577	1647	1626	4850
BinABC	Kesinlik	0.99	0.98	0.99	0.99	1.00	1.00	1.00	1.00
	Duyarlılık	0.98	0.98	0.99	0.99	0.99	1.00	1.00	1.00
	F1-Skoru	0.98	0.98	0.99	0.99	0.99	1.00	1.00	1.00
	Örnek Sayısı	1590	1648	1612	4850	1590	1648	1612	4850
iBinABC	Kesinlik	0.98	0.98	0.98	0.98	1.00	0.99	1.00	1.00
	Duyarlılık	0.98	0.98	0.98	0.98	0.99	1.00	1.00	1.00
	F1-Skoru	0.98	0.98	0.98	0.98	1.00	1.00	1.00	1.00
	Örnek Sayısı	1670	1587	1593	4850	1670	1587	1593	4850
NBABC	Kesinlik	0.98	0.99	0.98	0.98	0.99	1.00	0.99	0.99
	Duyarlılık	0.98	0.98	0.99	0.98	0.99	0.99	1.00	0.99
	F1-Skoru	0.98	0.98	0.98	0.98	0.99	0.99	0.99	0.99
	Örnek Sayısı	1636	1630	1584	4850	1636	1630	1584	4850
Ortak Kanallar	Kesinlik	0.96	0.98	0.95	0.97	0.98	0.99	0.99	0.99
	Duyarlılık	0.97	0.95	0.98	0.97	0.99	0.98	0.99	0.99
	F1-Skoru	0.97	0.97	0.97	0.97	0.99	0.99	0.99	0.99
	Örnek Sayısı	1616	1621	1613	4850	1616	1621	1613	4850
Tüm Kanallar	Kesinlik	0.94	0.94	0.97	0.95	0.96	0.95	0.98	0.96
	Duyarlılık	0.97	0.96	0.93	0.95	0.98	0.97	0.94	0.96
	F1-Skoru	0.95	0.95	0.95	0.95	0.97	0.96	0.96	0.96
	Örnek Sayısı	1617	1599	1634	4850	1617	1599	1634	4850

BÖLÜM 5

SONUÇLAR

Duygu tanımada EEG verilerinden kritik kanalların seçilmesi ve uygun özellik çıkarma yönteminin kullanılması çok önemlidir. Bunun yanında doğru sınıflandırma algoritmasını kullanmak gerekir. Geleneksel algoritmalar, EEG verilerinin kendi içindeki komşuluk ilişkisini ve hiyerarşik düzeni tanımlayamaz. Bu tez çalışmasında kişilerin duygu durumlarının yüksek doğruluk oranında tahmin edilebilmesi için iki ayrı çalışma yapılmıştır.

Birinci çalışmada, gelişmiş kapsül ağı tabanlı sınıflandırma modeli sayesinde EEG ölçüm verilerinin yanı sıra duyguyu tanımak için gerekli komşuluk ilişkisi ve hiyerarşik düzen de ağı öğretilmiştir. Orijinal CapsNet mimarisi, girdi verilerinin daha derin özelliklerini elde etmekte zorlandığından, evrişim katmanlarının sayısı ikiye çıkarılmış ve bu katmanlardaki çekirdek 5x5 olarak tanımlanmıştır. Çalışma sonucunda, EEG sinyallerinden uygun kanalların seçilmesine, Welch güç spektral yoğunluk tahmini ile özellik çıkarımına ve gelişmiş kapsül ağına dayalı yöntemin diğer yöntemlere göre daha yüksek doğrulukta sonuçlar verdiği tespit edilmiştir.

Yapılan ikinci çalışmada Seed EEG veriseti üzerinde pozitif, negatif ve nötr duygu sınıfları için en etkili kanallar DisABC algoritması ile belirlenmiştir. Bunun yanında Welch güç spektral yoğunluğu tahmini özellik çıkarma yöntemi sayesinde, bu kanallara ait ölçüm verilerinin sağlam ve tutarlı şekilde temsil edilmesi sağlanmıştır. Gelişmiş kapsül ağı sınıflandırma modeli ise verilerdeki derin özelliklerin tespit edilebilmesine olanak sağlarken aynı zamanda EEG kanallarının birbiri ile olan komşuluk ilişkisinin ve hiyerarşik düzeninin de ağı tanımlanabilmesini sağlamıştır.

Gelecekte, EEG kanallarının komşuluk ilişkisini ve hiyerarşik düzenini daha iyi tanımlayabilen farklı özellik seçme ve çıkarma yöntemleri ile daha doğru sonuçlar

verebilen sınıflandırma modelleri kullanılarak daha sağlam ve tutarlı sonuçlar elde edilebilir. Ayrıca çalışmada kullanılan Seed EEG veri setinde toplam 15 denek kullanılmıştır. İlerleyen zamanlarda denek sayısı artırıldığında daha başarılı sonuçlar alınabilir.

KAYNAKLAR

1. Zheng, W.-L., H.-T. Guo, and B.-L. Lu. "Revealing critical channels and frequency bands for emotion recognition from EEG with deep belief network." in *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*. IEEE, (2015).
2. Cote-Allard, U., et al., "Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning". *Ieee Transactions on Neural Systems and Rehabilitation Engineering*, **27**(4): 760-771, (2019).
3. Zubair, M., J. Kim, and C. Yoon, "An Automated ECG Beat Classification System Using Convolutional Neural Networks." *2016 6th International Conference on It Convergence and Security (Icits 2016)*, 335-339, (2016).
4. Martinez, H.P., Y. Bengio, and G.N. Yannakakis, "Learning Deep Physiological Models of Affect." *Ieee Computational Intelligence Magazine*, **8**(2): 20-33, (2013).
5. Ahern, G.L. and G.E. Schwartz, "Differential Lateralization for Positive and Negative Emotion in the Human-Brain - Eeg Spectral-Analysis." *Neuropsychologia*, **23**(6): 745-755, (1985).
6. Sammler, D., et al., "Music and emotion: Electrophysiological correlates of the processing of pleasant and unpleasant music." *Psychophysiology*, **44**(2): 293-304, (2007).
7. Mathersul, D., et al., "Investigating models of affect: Relationships among EEG alpha asymmetry, depression, and anxiety." *Emotion*, **8**(4): 560-572, (2008).
8. Knyazev, G.G., J.Y. Slobodskoj-Plusnin, and A.V. Bocharov, "Gender Differences in Implicit and Explicit Processing of Emotional Facial Expressions as Revealed by Event-Related Theta Synchronization." *Emotion*, **10**(5): 678-687, (2010).
9. Zheng, W.L. and B.L. Lu, "Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks." *Ieee Transactions on Autonomous Mental Development*, **7**(3): 162-175, (2015).
10. Palus, M., "Nonlinearity in normal human EEG: Cycles, temporal asymmetry, nonstationarity and randomness, not chaos." *Biological Cybernetics*, **75**(5): 389-396, (1996).

11. Lotte, F., et al., "A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update." **Journal of Neural Engineering**, **15**(3), (2018).
12. Li, M. and B.L. Lu, "Emotion Classification Based on Gamma-band EEG." **2009 Annual International Conference of the Ieee Engineering in Medicine and Biology Society**, Vols 1-20 :1323-1326, (2009).
13. Bos, D.O., "EEG-based emotion recognition." **The Influence of Visual and Auditory Stimuli**, **56**(3): 1-17, (2006).
14. Valenzi, S., et al., "Individual classification of emotions using EEG." **Journal of Biomedical Science and Engineering**, **7**(08): 604, (2014).
15. Agrawal, P., et al., "Metaheuristic Algorithms on Feature Selection: A Survey of One Decade of Research (2009-2019)." **IEEE Access**, **9**: 26766-26791, (2021).
16. Alweshah, M., et al., "A hybrid mine blast algorithm for feature selection problems." **Soft Computing**, **25**(1): 517-534, (2021).
17. Hedar, A.-R., J. Wang, and M. Fukushima, "Tabu search for attribute reduction in rough set theory." **Soft Computing**, **12**(9): 909-918, (2008).
18. Jensen, R. and Q. Shen, "Semantics-preserving dimensionality reduction: rough and fuzzy-rough-based approaches." **IEEE Transactions on knowledge and data engineering**, **16**(12): 1457-1471, (2004).
19. Mafarja, M. and S. Abdullah, "A fuzzy record-to-record travel algorithm for solving rough set attribute reduction." **International Journal of Systems Science**, **46**(3): 503-512, (2015).
20. Kabir, M.M., M. Shahjahan, and K. Murase, "A new local search based hybrid genetic algorithm for feature selection." **Neurocomputing**, **74**(17): 2914-2928, (2011).
21. Bello, R., et al. "Two-step particle swarm optimization to solve the feature selection problem." in **Seventh International Conference on Intelligent Systems Design and Applications (ISDA 2007)**, IEEE, (2007).
22. Kashef, S. and H. Nezamabadi-pour, "An advanced ACO algorithm for feature subset selection." **Neurocomputing**, **147**: 271-279, (2015).
23. Zorarpacı, E. and S.A. Özel, "A hybrid approach of differential evolution and artificial bee colony for feature selection." **Expert Systems with Applications**, **62**: 91-103, (2016).

24. Wang, J., T. Li, and R. Ren. "A real time IDSs based on artificial bee colony-support vector machine algorithm." in *Third International Workshop on Advanced Computational Intelligence*, IEEE, (2010).
25. Duan, R.N., J.Y. Zhu, and B.L. Lu, "Differential Entropy Feature for EEG-Based Emotion Classification." 2013 **6th International Ieee/Embs Conference on Neural Engineering (Ner)** : 81-84, (2013).
26. Islam, M.R. and M. Ahmad. "Wavelet Analysis Based Classification of Emotion from EEG Signal." in *2019 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, IEEE, (2019).
27. Lai, D.K., et al., "Prognosis of Sleep Bruxism Using Power Spectral Density Approach Applied on EEG Signal of Both EMG1-EMG2 and ECG1-ECG2 Channels." *Ieee Access*, **7**: 82553-82562, (2019).
28. Hinton, G.E. and R.R. Salakhutdinov, "Reducing the dimensionality of data with neural networks." *Science*, **313**(5786): 504-507, (2006).
29. Wu, Z.F., C.H. Shen, and A. van den Hengel, "Wider or Deeper: Revisiting the ResNet Model for Visual Recognition." *Pattern Recognition*, **90**: 119-133, (2019).
30. Rifai, S., et al. "Contractive auto-encoders: Explicit invariance during feature extraction." in *Proceedings of the 28th International Conference on International Conference on Machine Learning*, Omnipress, (2011).
31. Krizhevsky, A., I. Sutskever, and G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks." *Communications of the Acm*, **60**(6): 84-90, (2017).
32. LeCun, Y. and Y. Bengio, "Convolutional networks for images, speech, and time series." *The handbook of brain theory and neural networks*, **3361**(10): 1995, (1995).
33. Hinton, G.E., S. Osindero, and Y.W. Teh, "A fast learning algorithm for deep belief nets." *Neural Computation*, **18**(7): 1527-1554, (2006).
34. Li, Y.J., et al., "Human Emotion Recognition with Electroencephalographic Multidimensional Features by Hybrid Deep Neural Networks." *Applied Sciences-Basel*, **7**(10), (2017).
35. Li, S. and H. Feng. "EEG Signal Classification Method Based on Feature Priority Analysis and CNN." in *2019 International Conference on Communications, Information System and Computer Engineering (CISCE)*. IEEE, (2019).

36. Wang, J., et al. "Classification of EEG signal using convolutional neural networks." in *2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, IEEE, (2019).
37. Özcan, C. and H. Çizmecı. "EEG Based Emotion Recognition with Convolutional Neural Networks." in *2020 28th Signal Processing and Communications Applications Conference (SIU)*, Ieee, (2020).
38. Ha, K.W. and J.W. Jeong, "Decoding Two-Class Motor Imagery EEG with Capsule Networks." *2019 Ieee International Conference on Big Data and Smart Computing (Bigcomp)* : 387-390, (2019).
39. Chao, H., et al., "Emotion Recognition from Multiband EEG Signals Using CapsNet." *Sensors*, **19**(9), (2019).
40. Abhang, P.A., B.W. Gawali, and S.C. Mehrotra, "Technological basics of EEG recording and operation of apparatus." **Introduction to EEG-and speech-based emotion recognition** : 19-50, (2016).
41. Stinson, B. and D. Arthur, "A novel EEG for alpha brain state training, neurobiofeedback and behavior change." **Complementary therapies in clinical practice**, **19**(3): 114-118, (2013).
42. Abhang, P.A., B. Gawali, and S.C. Mehrotra, "Introduction to EEG-and speech-based emotion recognition.", **Academic Press**, (2016).
43. Niedermeyer, E., "Niedermeyer's electroencephalography: basic principles, clinical applications, and related fields.", **Lippincott Williams & Wilkins**, (2011).
44. Aldemir, R., "Dikkat eksikliği ve hiperaktivite bozukluğu olan çocuklarda ilaçla tedavi sürecinin EEG analizleriyle değerlendirilmesi / Evaluation of drug treatment processes of children with attention deficit and hyperactivity by EEG analysis", in *Fen Bilimleri Enstitüsü / Biyomedikal Mühendisliği Anabilim Dalı*, Erciyes University, (2019).
45. Klem, G.H., et al., "The ten-twenty electrode system of the International Federation." **Electroencephalogr Clin Neurophysiol**, **52**(3): 3-6, (1999).
46. Nuwer, M.R., et al., "IFCN standards for digital recording of clinical EEG." **Electroencephalography and Clinical Neurophysiology**, **106**(3): 259-261, (1998).
47. Committee, E.P.N., "Guideline thirteen: guidelines for standard electrode position nomenclature." **J. Clin. Neurophysiol.**, **11**: 111-113, (1994).
48. Nomenclature, S.E.P., "American electroencephalographic society guidelines for." **Journal of clinical Neurophysiology**, **8**(2): 200-202, (1991).

49. Chatrian, G., E. Lettich, and P. Nelson, "Ten percent electrode system for topographic studies of spontaneous and evoked EEG activities." **American Journal of EEG technology**, **25**(2): 83-92, (1985).
50. Jasper, H., "Report of the committee on methods of clinical examination in electroencephalography." **Electroencephalogr Clin Neurophysiol**, **10**: 370-375, (1958).
51. Liu, Y., et al., "Multi-channel EEG-based emotion recognition via a multi-level features guided capsule network." **Computers in Biology and Medicine**, **123**: 103927, (2020).
52. Katsigiannis, S. and N. Ramzan, "DREAMER: A database for emotion recognition through EEG and ECG signals from wireless low-cost off-the-shelf devices." **IEEE journal of biomedical and health informatics**, **22**(1): 98-107, (2017).
53. Koelstra, S., et al., "Deap: A database for emotion analysis; using physiological signals." **IEEE transactions on affective computing**, **3**(1): 18-31, (2011).
54. Dokeroglu, T., et al., "A survey on new generation metaheuristic algorithms." **Computers & Industrial Engineering**, **137**: 106040, (2019).
55. Karaboga, D. and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm." **Journal of global optimization**, **39**(3): 459-471, (2007).
56. Kiran, M.S. and M. Gündüz, "XOR-based artificial bee colony algorithm for binary optimization." **Turkish Journal of Electrical Engineering & Computer Sciences**, **21**(Sup. 2): 2307-2328, (2013).
57. Kashan, M.H., N. Nahavandi, and A.H. Kashan, "DisABC: a new artificial bee colony algorithm for binary optimization." **Applied Soft Computing**, **12**(1): 342-352, (2012).
58. Durgut, R., "Improved binary artificial bee colony algorithm." **Frontiers of Information Technology & Electronic Engineering**, **22**(8): 1080-1091, (2021).
59. Santana Jr, C.J., et al., "A novel binary artificial bee colony algorithm." **Future Generation Computer Systems**, **98**: 180-196, (2019).
60. Liu, H. and H. Motoda, "Feature selection for knowledge discovery and data mining." Vol. 454 : **Springer Science & Business Media**, (2012).
61. Liu, H. and L. Yu, "Toward integrating feature selection algorithms for classification and clustering." **IEEE Transactions on knowledge and data engineering**, **17**(4): 491-502, (2005).

62. Welch, P., "The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms." **IEEE Transactions on audio and electroacoustics**, **15**(2): 70-73, (1967).
63. Kumar, N., K. Alam, and A.H. Siddiqi, "Wavelet transform for classification of eeg signal using svm and ann." **Biomedical and Pharmacology Journal**, **10**(4): 2061-2069, (2017).
64. Mallat, S.G., "A theory for multiresolution signal decomposition: the wavelet representation." **IEEE Transactions on Pattern Analysis & Machine Intelligence**, (7): 674-693, (1989).
65. Meyer, Y., "Wavelets and operators." Vol. 1: **Cambridge university press**, (1992).
66. Cohen, A., "Ten Lectures on Wavelets", **CBMS-NSF Regional Conference Series in Applied Mathematics**, Vol. 61, I. Daubechies, SIAM, 1992, xix+ 357 pp. **Journal of Approximation Theory**, **78**(3): 460-461, (1994).
67. Patrick, M.K., et al., "Capsule networks—a survey." **Journal of King Saud University-Computer and Information Sciences**, (2019).
68. Nielsen, M.A., "Neural networks and deep learning." Vol. 2018: **Determination press San Francisco, CA, USA**, (2015).
69. LeCun, Y., et al., "Neural networks: Tricks of the trade." **Springer Lecture Notes in Computer Sciences**, **1524**(5-50): 6, (1998).
70. Pattanayak, S., Pattanayak, and S. John, "Pro Deep Learning with TensorFlow.", **Springer**, (2017).
71. Glorot, X., A. Bordes, and Y. Bengio. "Deep sparse rectifier neural networks." in **Proceedings of the fourteenth international conference on artificial intelligence and statistics**. (2011).
72. Gao, B. and L. Pavel, "On the properties of the softmax function with application in game theory and reinforcement learning." **arXiv preprint arXiv:1704.00805**, (2017).
73. Engelbrecht, A.P., "Computational intelligence: an introduction.", **John Wiley & Sons**, (2007).
74. Scherer, D., A. Müller, and S. Behnke. "Evaluation of pooling operations in convolutional architectures for object recognition." in **International conference on artificial neural networks**, Springer, (2010).

75. DiPietro, R., "A friendly introduction to cross-entropy loss." URL <https://rdipietro.github.io/friendly-intro-to-cross-entropy-loss>, (2016).
76. Sabour, S., N. Frosst, and G.E. Hinton, "Dynamic Routing Between Capsules." **Advances in Neural Information Processing Systems 30 (Nips 2017)**, 30, (2017).
77. Su, J., D.V. Vargas, and K. Sakurai, "One pixel attack for fooling deep neural networks." **IEEE Transactions on Evolutionary Computation**, 23(5): 828-841, (2019).
78. Shahroudnejad, A., et al. "Improved explainability of capsule networks: Relevance path by agreement." in **2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP)**, IEEE, (2018).
79. Hinton, G.E., A. Krizhevsky, and S.D. Wang, "Transforming Auto-Encoders." **Artificial Neural Networks and Machine Learning - Icann 2011**, Pt I, 6791: 44-51, (2011).
80. Hinton, G.E., S. Sabour, and N. Frosst, "Matrix capsules with EM routing.", (2018).
81. Engelin, M., "CapsNet Comprehension of Objects in Different Rotational Views: A comparative study of capsule and convolutional networks.", (2018).
82. Huang, G., et al., "Densely Connected Convolutional Networks." **30th Ieee Conference on Computer Vision and Pattern Recognition (Cvpr 2017)**, 2261-2269, (2017).
83. Simonyan, K. and A. Zisserman, "Very deep convolutional networks for large-scale image recognition." **arXiv preprint arXiv:1409.1556**, (2014).
84. Lecun, Y., et al., "Gradient-based learning applied to document recognition." **Proceedings of the Ieee**, 86(11): 2278-2324, (1998).
85. He, K.M., et al., "Deep Residual Learning for Image Recognition." **2016 Ieee Conference on Computer Vision and Pattern Recognition (Cvpr)**, 770-778, (2016).
86. Jaitly, N. and G. Hinton, "Learning a Better Representation of Speech Soundwaves Using Restricted Boltzmann Machines." **2011 Ieee International Conference on Acoustics, Speech, and Signal Processing**, 5884-5887, (2011).
87. Mohamed, A.R., D. Yu, and L. Deng, "Investigation of Full-Sequence Training of Deep Belief Networks for Speech Recognition." **11th Annual Conference of the International Speech Communication Association (Interspeech 2010)**, Vols 3 and 4, 2010: 2850+, (2010).

88. Cizmeci, H. and C. Ozcan, "*Enhanced deep capsule network for EEG-based emotion recognition.*" **Signal, Image and Video Processing**, 1-7, (2022).

ÖZGEÇMİŞ

Hüseyin ÇİZMECİ ilk ve orta öğrenimini Çorum/İskilip'te tamamladı. İskilip Lisesi'nden 2002 yılında mezun oldu. 2004 yılında Gazi Üniversitesi Sungurlu Meslek Yüksekokulu Bilgisayar Teknolojisi ve Programlama bölümünü yüksek onur belgesi ile bölüm ikincisi ve okul üçüncüsü olarak bitirdi. 2005 - 2009 yılları arası Ahmet Yesevi Üniversitesi Bilgisayar Mühendisliği bölümünde lisans eğitimini, 2009-2011 yılları arası yine aynı bölümün ve üniversitenin yüksek lisans eğitimini tamamladı. 2016 yılında Karabük Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı'nda başladığı doktora eğitimine devam etmektedir. 2012 tarihinden itibaren Hitit Üniversitesi'nde görev yapmaktadır.