



İSKENDERUN TEKNİK
ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**Yüzey EMG Sinyallerinin
Öznitelik Optimizasyonu ve
Makine Öğrenmesi Yöntemleri
ile Sınıflandırılması**

Muhammed Sami KARAKUL

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

MAYIS 2025





**YÜZEY EMG SİNYALLERİNİN ÖZNİTELİK OPTİMİZASYONU VE
MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE SINIFLANDIRILMASI**

Muhammed Sami KARAKUL

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

MAYIS 2025

Muhammed Sami KARAKUL tarafından hazırlanan “Yüzey EMG Sinyallerinin Öznitelik Optimizasyonu ve Makine Öğrenmesi Yöntemleri ile Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Ahmet GÖKÇEN

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Başkan: Prof. Dr. Celaleddin YEROĞLU

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Üye: Dr. Öğr. Üyesi Mehmet SARIGÜL

Bilgisayar Mühendisliği, Çukurova Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....

Tez Savunma Tarihi: 07/05/2025

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Abdullah ÖZKAN

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- ☒ Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- ☒ Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- ☒ Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- ☒ Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- ☒ Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ☒ Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Muhammed Sami KARAKUL

07/05/2025

YÜZEY EMG SİNYALLERİNİN ÖZNİTELİK OPTİMİZASYONU VE MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE SINIFLANDIRILMASI
(Yüksek Lisans Tezi)

Muhammed Sami KARAKUL

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Mayıs 2025

ÖZET

Kas aktivitelerinde oluşan sinyaller olan elektromiyografi (EMG) sinyalleri el, kol hareketleri gibi çeşitli eylemlerin tespiti ve sınıflandırması için kullanılabilir. EMG sinyallerinin ölçümleri deri altına yerleştirilen elektrotlar ile veya yüzey üstü olarak kaydedilebilir. Deri altına girilmesi gerekmeden yapılan ölçümlerden elde edilen sinyallere yüzey elektromiyografi (surface electromyography, sEMG) sinyalleri denir. Bu çalışmada biri özgün oluşturulmuş iki farklı veri seti kullanılmıştır. İlk veri seti, katılımcıların parmak hareketlerinin sınıflandırılması için, ikinci veri seti ise katılımcıların cinsiyetlerini tespit etmek için kullanılmıştır. Bu çalışmada sınıflandırıcı olarak geleneksel makine öğrenmesi ve derin öğrenme yöntemleri seçilmiştir. Özniteliklerin anlamlı olanlarını seçip, anlamı bozan özniteliklerden sistemimizi uzak tutabilmek için Ağaç-Tohum Algoritması (Tree-Seed Algorithm, TSA) kullanılarak optimizasyon yapılmış ve Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) yöntemi ile performans karşılaştırılması yapılmıştır. Çalışmada gösterilen yöntemler neticesinde veri setlerini kullanan geçmiş çalışmaların başarımları aşılmıştır. İkinci veri setinde yapılan çalışmada, katılımcıların yazma alışkanlıklarına göre literatürde ilk olarak, ön kol sEMG verilerinden cinsiyet tespiti yapılmıştır.

Anahtar Kelimeler : Elektromiyografi, yüzey elektromiyografisi, makine öğrenmesi, derin öğrenme, optimizasyon

Sayfa Adedi : 62

Danışman : Doç. Dr. Ahmet GÖKÇEN

CLASSIFICATION OF SURFACE EMG SIGNALS WITH FEATURE
OPTIMIZATION AND MACHINE LEARNING METHODS

(M. Sc. Thesis)

Muhammed Sami KARAKUL

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

May 2025

ABSTRACT

Electromyography (EMG) signals, which are generated from muscle activities, can be utilized for the detection and classification of various actions such as hand and arm movements. EMG signals can be recorded either through electrodes placed beneath the skin or on the surface. Signals obtained from measurements conducted without penetrating the skin are referred to as surface electromyography (sEMG) signals. In this study, two distinct datasets, one of which is unique, were used. The first dataset was employed for classifying finger movements of participants, while the second dataset was developed for the purpose of detecting the gender of participants. Traditional machine learning and deep learning methods were selected as classifiers in this study. Optimization was performed using the Tree-Seed Algorithm (TSA) to select the meaningful features and exclude those that would disrupt the system's performance. Performance comparisons were made using the Particle Swarm Optimization (PSO) method. As a result of the methods presented in this study, the performance achieved surpassed that of previous studies utilizing the same datasets. In the study conducted with the second dataset, gender detection according to the participants' writing habits based on forearm sEMG data was performed for the first time in the literature.

Key Words : Electromyography, surface electromyography, machine learning, deep learning, optimization

Page Number : 62

Supervisor : Assoc. Prof. Dr. Ahmet GÖKÇEN

TEŞEKKÜR

Sahip olduđu bilgi birikimi ve tecrübesi ile çalışmayı sabır ve anlayışıyla yönlendiren, hiçbir yardımı esirgemeyen saygıdeğer danışman hocam Doç. Dr. Ahmet GÖKÇEN'e sonsuz saygı ve teşekkürlerimi sunarım.

Çalışmalarım boyunca beni destekleyen ve neşeleri ile çalışma isteğimi arttıran Batuhan KARADAĞ'a, Mehmet UZEL'e ve Mahmut Erkan DEMİR'e teşekkür ederim.

Her zaman yanımda olduklarını ve bana inançlarını yitirmediklerini bildiğim babam Şener KARAKUL'a, annem Nazan KARAKUL'a ve sevgili kardeşim Nesibe Nur KARAKUL'a minnetlerimi sunarım.

Azmimin azaldığı her anımda sözleri, desteğı ve en önemlisi varlığı ile yanımda olan Merve Nilay AYDIN'a eksilmeyen neşesi ve bana kattığı her şey için teşekkür ederim.

İÇİNDEKİLER	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
RESİMLERİN LİSTESİ	xiii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. MATERYAL VE YÖNTEM	6
2.1. Elektromiyografi Yapısı	6
2.2. Thalmic Labs MyoArmband	6
2.3. Veri Setleri	7
2.3.1. Veri seti 1 (Electromyography(EMG) dataset).....	7
2.3.2. Veri seti 2 (Özgün sEMG veri seti)	7
2.4. Makine Öğrenmesi	9
2.4.1. k-En yakın komşu (k-Nearest neighbor, kNN).....	9
2.4.2. Destek vektör makineleri (support vector machines, SVM).....	10
2.4.3. Karar ağaçları (Decision trees, DT)	11
2.4.4. Rastgele orman (Random Forest, RF).....	11
2.5. Derin Öğrenme.....	12
2.5.1. Yapay sinir ağları	12
2.5.2. Evrimsel sinir ağları (convolutional neural networks – CNN).....	13
2.6. Ön İşleme	14

2.6.1. Dalgacık dönüşümü (wavelet transform, WT).....	15
2.6.2. Ayrık dalgacık dönüşümü (dicrete wavelet transform, WT).....	15
2.7. Öznitelik Çıkarımı.....	15
2.7.1. Zaman alanı öznitelikleri.....	15
2.7.2. Frekans alanı öznitelikleri	18
2.7.3. Pencereleme ve kayan pencereler	19
2.8. Optimizasyon Algoritmaları.....	20
2.8.1. Parçacık sürü optimizasyonu (particle swarm optimization, PSO).....	20
2.8.2. Ağaç-tohum algoritması (tree-seed algorithm, TSA).....	21
2.9. Performans Çıktıları İçin Hesaplamalar	26
2.9.1. Doğruluk (Accuracy)	27
2.9.2. Hassasiyet (Precision)	27
2.9.3. Duyarlılık (Recall)	27
2.9.4. F1-Skoru (F1-Score)	27
3. ARAŞTIRMA BULGULARI	28
3.1. Emg Tabanlı Parmak Hareketi Tanıma ve Pencere Boyutu Karşılaştırması	28
3.2. Dalgacık Dönüşümü Tabanlı Parmak Hareketi Tanıma	31
3.3. Ağaç Tohumu Algoritması ile Makine Öğrenme Algoritmalarını Kullanarak Parmak Hareketi Tanıma.....	34
3.3.2. Amaç fonksiyonu	36
3.4. Cinsiyet Tespiti Çalışması.....	40
3.4.1. Öznitelik çıkarımı.....	43
3.4.2. CNN Mimarileri	43
4. SONUÇLAR.....	53
5. KAYNAKLAR	54

6. EKLER.....	61
---------------	----



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Katılımcılardan yazmaları istenen kelimelerin listesi	9
Çizelge 3.1. CNN modelinin hiper-parametre tablosu	32
Çizelge 3.2. Dalgacıklardan elde edilen özniteliklerin başarımlar metrikleri	32
Çizelge 3.3. PSO ve TSA kullanılarak elde edilen başarımlar	38
Çizelge 3.4. Literatürde bulunan çalışmalar ile kıyas tablosu	39
Çizelge 3.5. Modeller için hiper-parametreler	45
Çizelge 3.6. Modellerin çeşitli pencere ve kayma boyutları ile başarımlar metrikleri	46
Çizelge 3.7. Modellerin, normalize edilmiş çeşitli pencere ve kayma boyutları ile başarımlar metrikleri	47
Çizelge 3.8. En iyi başarımları veren modellerin metrikleri	48
Çizelge 3.9. Literatürde bulunan çalışmalar ile kıyaslama tablosu	51

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. MyoArmband isimli cihazdan alınan 8 kanal sEMG verileri.....	8
Şekil 2.2. kNN için $k=3$ ve $k=7$ için örnek sınıflandırma.....	10
Şekil 2.3. Karar ağacı.....	11
Şekil 2.4. Rastgele orman	12
Şekil 2.5. Evrişimsel sinir ağları	13
Şekil 2.6. Üst üste binen kayan pencere örneği	20
Şekil 2.7. Ağaç-Tohum algoritması, ağaçların oluşturulması.....	22
Şekil 2.8. Ağaç-Tohum algoritması, en iyi ağacın seçilmesi.....	23
Şekil 2.9. Ağaç-Tohum Algoritması, ağaçların tohumlarının oluşturulması.....	23
Şekil 2.10. Ağaç-Tohum Algoritması, ağaçların en iyi tohumlarının seçilmesi.....	24
Şekil 2.11. Ağaç-Tohum algoritması, ağaçların en iyi tohumları ile kıyaslanması sonucu	24
Şekil 2.12. Ağaç-Tohum algoritması, iterasyon sonucu en iyi ağacın seçilmesi.....	25
Şekil 2.13. Karmaşıklık matrisi	26
Şekil 3.1. Pencere boyutlarına göre doğruluk oranı.....	29
Şekil 3.2. RF ve SVM için en iyi ve en kötü başarımların karmaşıklık matrisleri	30
Şekil 3.3. CNN modelinin mimarisi	31
Şekil 3.4. Dalgacıkların karmaşıklık matrisleri	33
Şekil 3.5. Amaç fonksiyonunun üzerinde çalıştığı noktaların örnek gösterimi	36
Şekil 3.6. Önerilen CNN modeli.....	44
Şekil 3.7. VGG16 modelinin 1D mimarisi	44
Şekil 3.8. AlexNET modelinin 1D mimarisi	45
Şekil 3.9. Normalize edilmeyen ve normalize edilen öznitelikler ile farklı pencerelerden elde edilen başarımlar	48

Şekil**Sayfa**

Şekil 3.10. Normalize edilmeyen ve normalize edilen öznitelikler için önerilen CNN mimarisinin en iyi başarımlarını veren pencere boyutlarının doğruluk grafikleri	49
--	----



RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 2.1. Thalmic Lab MyoArmband Cihazı.....	6
Resim 2.2. Katılımcılardan veri alınma sürecine dair örnek görsel.....	8



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
1D	Tek Boyutlu
AAC	Ortalama Genlik Değişimi
ADC	Analog-Dijital Dönüştürücü
ANN	Yapay Sinir Ağları
AP	Ortalama Kuvvet
AUC-RMS	Eğri Altındaki Alan Kök Ortalama Karesi
Bi-LSTM	Çift Yönlü Uzun Kısa Vadeli Bellek
BPSODE	İkili Parçacık Sürüsü Optimizasyonu Diferansiyel Evrim
CBGWO	Rekabetçi İkili Gri Kurt Optimizasyonu
CFA	Kombinatoryal Füzyon Yöntemi
CNN	Evrişimsel Sinir Ağları
DT	Karar Ağaçları
DWT	Ayrık Dalgacık Dönüşümü
EEG	Elektroensefalografi
EKG	Elektrokardiyografi
ELM	Aşırı Öğrenme Makinesi
EMG	Elektromiyografi
FN	Yanlış Negatif
FP	Yanlış Pozitif
FR	Frekans Oranı
GA	Genetik Algoritma
GGABC	Küresel En İyi Rehberli Gaussian Yapay Arı Kolonisi
HRV	Kalp Atış Hızı Değişkenliği
kNN	k-En Yakın Komşu
KP	Karşılaştırma Parametresi
KPCA	Çekirdek Ana Bileşen Analizi

Kısaltmalar**Açıklamalar**

LDA	Doğrusal Diskrimant Analizi
LHC	Alt Harmonik Bileşeni
LLC	Alt Kesim Frekansı
LSTM	Uzun Kısa Süreli Bellek
MAV	Ortalama Mutlak Değer
MDF	Medyan Frekans
MFL	Maksimum Fraktal Uzunluğu
MLP	Çok Katmanlı Algılayıcı
MNF	Ortalama Frekans
MPF	Ortalama Güç Frekansı
NB	Naive Bayes
PBPSO	Kişisel En İyi Rehber İkili Parçacık Sürüsü Optimizasyonu
PBGR	Parça-Tabanlı Cinsiyet Tanıma
Local-DNN	Yerel Derin Sinir Ağları
PCA	Ana Bileşen Analizi
PLV	Faz-Kilitli Değer
PSO	Parçacık Sürü Optimizasyonu
ReLU	Düzeltilmiş Doğrusal Birim
RBFN	Radyal Baz Fonksiyon Ağı
RF	Rastgele Orman
RFE	Özyinelemeli Öznitelik Eleme
RF-RFE	Rastgele Orman Tabanlı Özyinelemeli Öznitelik Eleme
RMS	Karekök Ortalama
RNN	Tekrarlayan Evrişimsel Sinir Ağı
sEMG	Yüzey Elektromiyografi
SSC	Eğim İşaret Değişikliği
ST	Arama Eğilimi
STD	Standart Sapma
SVM	Destek Vektör Makineleri
SVM-RFE	SVM Tabanlı Özyinelemeli Öznitelik Eleme
TN	Doğru Negatif

Kısaltmalar**Açıklamalar**

TP	Doğru Pozitif
TSA	Ağaç-Tohum Algoritması
TTP	Toplam Güç
UHC	Üst Harmonik Bileşeni
ULC	Üst Kesim Frekansı
VAR	Varyans
WL	Dalga Boyutu
WT	Dalgacık Dönüşümü
ZC	Sıfır Geçişi

1. GİRİŞ

Kaslarımızın hareket etmesi beyinden gelen elektriksel işaretlerin sinir hücreleri vasıtasıyla kaslara iletilmesi ile gerçekleştirilir. Bu elektriksel işaretlere elektromiyografi (EMG) sinyalleri denir. EMG sinyallerini elde edebilmek için deri altına nüfuz etmeyi gerektirmeyen yüzey (surface electromyography, sEMG) elektrotları veya deri altına (invaziv) yerleştirilen elektrotlar kullanılmaktadır (Hu, Wong, Wei, Du, Kankanhalli ve Geng, 2018).

EMG sinyalleri protez ve cihaz kontrolleri, insan-bilgisayar etkileşimleri, el, kol, parmak hareketleri gibi çeşitli aktivitelerin tespit edilmesi amacıyla sıklıkla kullanılmaktadır. (Jaramillo-Yáñez, Benalcázar ve Mena-Maldonado, 2020)

Literatüre bakıldığında, Kim ve arkadaşları radyo kontrollü bir aracı EMG sinyalleri ile kontrol etmeyi hedeflemişlerdir. Çalışmalarında EMG sensörlerini, kullanıcının ön kol bölgesine yerleştirerek verileri kaydetmişlerdir. Araştırmacılar, k-En Yakın Komşu (k-Nearest Neighbor, kNN) ve Bayes sınıflandırıcılarını birleştirerek karar ağacına benzer bir yapı oluşturmuşlardır. Oluşturdukları yapıyı iki farklı kombinasyonla deneyen araştırmacılar çalışmalarının sonunda 94.33% başarımla oranı ile sınıflandırma yapabilmişlerdir (Kim, Mastnik ve André, 2008).

Zhou ve arkadaşları, topluluk kullanımına açık, on farklı kullanıcının EMG verilerini içeren bir EMG veri seti üzerinden çıkarttıkları dokuz özneliği sınıflandırıcılar ile kıyaslamışlardır. Zaman alanında çıkarttıkları dokuz özneliği tekil ve farklı kombinasyonlar ile deneyen araştırmacılar, sınıflandırıcı olarak rastgele orman (Random Forest, RF) algoritmasını seçip 92.94% sınıflandırma başarımla elde etmişlerdir (Zhou, Omisore, Du, Wang ve Zhang, 2019).

Bir diğer çalışmada Wahid ve arkadaşları Çoklu Pencere Çoğunluk Stratejisi (Multi Window Majority Strategy) yöntemini açık bir EMG veri seti üzerinde kullanmışlardır. Çalışmada, EMG sinyallerini 50 ile 500ms arasında değişen pencere ölçütü ile kullanıp üst üste binme oranı olarak 0% ile 80% arasındaki değerler seçmişler ve altı farklı sınıflandırma algoritması kullanarak en yüksek sınıflandırma başarımla 80.70% ile RF algoritmasından elde etmişlerdir (Wahid, Tafreshi ve Langari, 2020).

Geng ve arkadaşları, sEMG görsellerinden anlık olarak hareket sınıflandıran bir yöntem tanıtmışlardır. Çalışmalarında pencere yöntemini kullanarak ve kullanmayarak elde ettikleri sonuçları kıyaslayan araştırmacılar pencere yöntemini kullanırken 1000Hz

örnekleme ölçütü ile 40 adet örnek elde etmiş ve pencere yöntemini kullanmadan elde ettikleri tekil örnekler ile kıyaslamışlardır. Kıyaslamalarında derin Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNN) kullanan araştırmacılar, pencere kullanmadan elde ettikleri örneklerden 89.3% başarımla, pencere yöntemi kullanarak elde ettiklerini örneklerden ise 99.0% başarımla oranı elde etmişlerdir (Geng, Du, Jin, Wei, Hu ve Li, 2016).

Yapay sinir ağları (Artificial Neural Networks, ANN) ile sEMG sinyallerinin sınıflandırıldığı bir diğer çalışma da Tepe ve Erdim tarafından yapılmış, altı parmak hareketi sınıflandırmak için kullanılmıştır. Katılımcıların her hareketi 30 saniye uyguladıkları süreçte, araştırmacılar Thalmics Labs isimli şirketin ürünü olan MyoArmband cihazı ile sEMG ve jiroskopik verilerini kaydetmişlerdir. Yalnızca sEMG verilerini kullanarak yaptıkları sınıflandırma başarımları 94.40% olup, jiroskopik sinyallerin sEMG sinyalleri ile kullanımı sonrasında başarımlarını 96.30% oranına yükseltmişlerdir (Tepe ve Erdim, 2022).

Wahid ve arkadaşları, beş sağlıklı katılımcıdan MyoArmband ile topladıkları EMG sinyalleri ile üç el hareketini sınıflandırmayı hedeflemişlerdir. EMG özneliklerini Eğri Altındaki Alan Kök Ortalama Karesi (Area Under the Curve Root Mean Square, AUC-RMS) değeri ile normalize ederek kullanmış ve kıyaslama için kullandıkları çeşitli makine öğrenmesi algoritmaları ile test etmişlerdir. Çalışmalarının sonucunda Destek Vektör Makineleri (Support Vector Machines, SVM) ile 98.75% sınıflandırma başarımları elde etmişlerdir (Wahid, Tafreshi, Al-Sowaidi ve Langari, 2018).

MyoArmband kullanımında, MyoArmband'in giyim şeklinden bağımsız sınıflandırma yapılabileceğini göstermek isteyen Zhang ve arkadaşları katılımcıların ön kol bölgelerinden MyoArmband ile veri toplarken, katılımcılardan belirli hareketleri gerçekleştirmelerini istemişlerdir. Katılımcılar belirli hareket setini tamamladıklarında MyoArmband belirli bir açı ile döndürülmüş ve katılımcılardan tekrar aynı hareketi yapmaları istenmiştir. MyoArmband'in kolda duruş açısı ve giyiminden bağımsız bir sınıflandırma yapabildiklerini gösteren araştırmacılar 91.47% başarımla ulaşmışlardır (Zhang, Chen, Yu, Yang, Lu ve Liu, 2018).

Yukarıda anlatılan çalışmalarda araştırmacıların tamamı zaman alanında çalışmışlardır. EMG sinyallerini yalnızca zaman alanında değil, frekans alanını da kullanarak inceleyen ve sınıflandırmalarında frekans alanından da faydalanan çalışmalar bulunmaktadır.

Too ve arkadaşları, zaman ve frekans alanını kullanıp her ikisinden de elde ettikleri sonuçları karşılaştırmışlardır. Altı farklı parmak hareketinden oluşan veri setinden çıkarttıkları zaman ve frekans alanı öz niteliklerini ayrı ayrı Doğrusal Diskriminant Analizi (Linear Discriminant Analysis, LDA) yöntemi ile sınıflandırmışlardır. Çalışmalarının neticesinde frekans alanından çıkarttıkları öz nitelikler ile 91.34% başarımla elde ederken zaman alanından çıkarttıkları öz niteliklerin başarımları 87.17% değeri ile frekans alanının gerisinde kalmıştır (Too, Abdullah, Zawawi, Saad ve Musa, 2017).

Zaman ve frekans alanlarını kıyaslayan bir diğer çalışma Altın ve Er tarafından yapılmıştır. Çalışmalarında yazarlar, katılımcıların dirseklerinden topladıkları EMG sinyallerini, dirsek bükülmesi ve dirsek uzatması olarak iki sınıfa ayırmışlardır. Zaman alanından 11, frekans alanından ise 6 öz nitelik çıkartan araştırmacılar çıkarttıkları öz niteliklerin başarımlarını ayrı ayrı kNN sınıflandırıcısı ile incelemişlerdir. İncelemelerinin neticesinde zaman alanında 93% oranı ile en yüksek sınıflandırma başarımlarını veren öz nitelik Otomatik Gerileme Katsayısı (Auto Regressive Coefficient) olur iken, frekans alanında bu öz nitelik 83% başarımla Medyan Frekans (Median Frequency) öz niteliği olmuştur (Altın ve Er, 2016).

EMG sinyalleri yalnızca belirli hareketleri sınıflandırmak için değil aynı zamanda çeşitli tanımlar için de kullanılmaktadır. Tanı koymada faydalanılabileceğini gösteren bir çalışma da Duque ve arkadaşları, nöromüsküler bozukluklara tanı koymayı hedeflemişlerdir. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform, DWT) ile sinyallerini işleyip ardından kNN sınıflandırıcısı ile sinyalleri tanı koymak için kullanmışlardır. Dalgacık olarak Daubechies düzen 8 kullanarak elde ettikleri DWT sonucundan altı istatistiksel öz nitelik çıkartan Duque ve arkadaşları, ilgi analizi ile ve ilgi analizi olmadan öz niteliklerin başarımlarını kıyaslamışlardır. Elde ettikleri en yüksek başarımla değeri oranı olan 93.08% değerini stokastik ilgi yöntemi ile elde etmişlerdir (Duque, Muñoz, Mejía ve Trejos, 2015).

Literatürde optimizasyon algoritmaları ve EMG sinyallerinin birlikte kullanımını içeren çalışmalar mevcuttur.

Huang ve arkadaşları, öz nitelik seçimi için yeni bir karınca koloni optimizasyonu sunmuştur. On katılımcının, aynı sekiz el hareketini üç kez 80 saniye boyunca gerçekleştirirken kaydedilen EMG sinyalleri çalışmada kullanılan veri setini oluşturmuştur. Elde ettikleri başarımla karınca koloni optimizasyonu ile daha yüksek başarımla seviyelerine çıkartmayı hedefleyen Huang ve arkadaşları, daha yüksek başarımla daha az sayıda öz nitelik kullanarak elde etmeyi hedeflemiştir. Topladıkları EMG sinyalleri üzerinde farklı

öznitelik setleri oluşturan araştırmacılar, en yüksek başarıyı dalgacık dönüşümü (Wavelet Transform, WT) öznitelikleri ile $96.08 \pm 3.3\%$ ile elde etmişlerdir (Huang, Xie, Guo ve Chen, 2012).

Too ve arkadaşları, EMG sinyallerinin öznitelik seçimi problemi için rekabetçi ikili gri kurt optimizasyon algoritmasını (Competitive Binary Grey Wolf Optimizer, CBGWO) önermişlerdir. Önerdikleri optimize ediciyi NinaPro4 veri setinde kNN sınıflandırıcısı ile kullanmış ve kıyaslama için kullandıkları diğer optimizasyon algoritmalarının başarımlarını aşan 92.69% başarımları elde etmişlerdir (Too, Abdullah, Mohd Saad, Mohd Ali ve Tee, 2018).

Subasi çalışmasında EMG sinyallerini sınıflandırmak için Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) ve SVM yöntemlerini birleştirdikleri bir yöntem önermiştir. Sağlıklı, miyopatik ve nörojenik sağlık durumları bulunan 27 katılımcıdan EMG verilerini toplayan Subasi, çeşitli makine öğrenmesi yöntemleri ile kendi önerdikleri yöntemi kıyaslamış ve önerilen PSO-SVM yönteminin 97.41% oranı ile en yüksek başarımları verdiğini raporlamıştır (Subasi, 2013).

Bir başka çalışmada araştırmacılar öznitelik seçimi probleminin çözümü için optimizasyon algoritmalarına odaklanmış ve İkili Parçacık Sürüsü Optimizasyonu Diferansiyel Evrim (Binary Particle Swarm Optimization Differential Evolution, BPSODE) isimli yeni bir yöntem önermişlerdir. Araştırmacılar önerdikleri yöntemi farklı öznitelik seçim algoritmaları ile kıyaslamış ve 92.5% başarımları oranı ile en yüksek başarımları kendi önerdikleri yöntem ile ulaşmışlardır (Too, Abdullah ve Mohd Saad, 2019).

Too ve arkadaşları, Kişisel En İyi Rehber İkili Parçacık Sürüsü Optimizasyonu (Personal Best Guide Binary Particle Swarm Optimization, PBPSO) isimli bir yöntem önermiş ve önerdikleri yöntemi NinaPro3 veri seti üzerinde uygulamışlardır. Çalışmalarında kNN sınıflandırıcısını kullanan araştırmacılar, 85.20% başarımları oranı elde etmişlerdir (Too, Abdullah, Mohd Saad ve Tee, 2019).

Aynı sınıflandırıcıyı kullanan bir diğer çalışmada Sahu ve arkadaşları, önerdikleri yöntem ile global optimizasyon problemini çözmeyi hedeflemişlerdir. Önerdikleri yöntemi Küresel En İyi Yönlendirilmiş Gaussian Yapay Arı Kolonisi (Global Best Guided Gaussian Artificial Bee Colony, GGABC) olarak adlandıran Araştırmacılar yöntemlerini kNN ile sınıflandırıcısı ile kullanmış ve ortalama olarak 94.13% , en yüksek olarak ise 97.06% başarımları oranlarını raporlamışlardır (Sahu, Singh ve Nirala, 2023).

Jain ve arkadaşları, Genetik Algoritma (GA) ile ANN kullanarak EMG verilerini sınıflamış ve 95% doğruluk oranı elde etmiştir (Jain ve Garg, 2021).

Farag ve arkadaşları ise CNN ile sınıflandırarak biyonomik kol kontrolünü hedeflemiş ve 90.8% başarımla elde etmiştir (Farag ve diğerleri, 2021).

Bittibssi ve arkadaşları ise hareketleri sınıflandırmak için Uzun Kısa Süreli Bellek (Long-Term Short-Term Memory, LSTM) tabanlı Tekrarlayan Sinir Ağı (Recurrent Convolutional Neural Networks, RNN) kullanmışlardır. Araştırmacıların önerdikleri mimari, evrişimli LSTM ve RNN kullanan geçitli tekrarlayan ünite mimarisidir ve tahmin başarımlarını 99.6%'a çıkartmıştır (Bittibssi, Genedy ve Maged, 2021).

Bu tezde ilk olarak topluluğun kullanıma açık halde paylaşılan hazır EMG veri setleri ile hareket ve cinsiyet sınıflandırma yapılmıştır. Ayrıca tez kapsamında özgün bir veri seti oluşturulmuştur. Oluşturulan veri seti üzerinde tek boyutlu (1-Dimensional, 1D) CNN mimarileri uygulanmış ve cinsiyet tespiti yapılmıştır. Bu tezin literatüre yaptığı katkılara aşağıda listelenmiştir:

- Ağaç-Tohum Algoritması (Tree-Seed Algorithm, TSA) kullanılarak, hazır veri setinde literatürde bulunan çalışmalara kıyasla en yüksek doğruluk ile sınıflandırma başarımla doğruluk oranı elde edilmiştir.
- Ağaç-tohum algoritmasının öznetelik sayısını azaltırken sEMG sınıflandırma doğruluk oranını artırmak için kullanılabileceği gösterilmiştir.
- Özgün bir sEMG veri seti oluşturulmuştur.
- Literatürde daha önce ön kol sEMG verilerinden cinsiyet sınıflandırma problemi üzerinde daha önce kullanıldığına rastlanmamış bir CNN mimarisi sunulmuştur.
- Literatürde başarımla kanıtlanan, ön eğitilmiş kullanılan mimarilerin 1D CNN mimarileri ile kıyaslama yapılmıştır. Yapılan kıyasta çeşitli hiper-parametreler ve çeşitli pencere boyutları kullanılarak mimarilerin performansları arasında detaylı karşılaştırma yapılmıştır.
- Çalışma neticesinde yazma alışkanlıklarının cinsiyetler arasında farklılık gösterdiğinin ön kol sEMG sinyalleri ile tespit edilebildiği görülmüştür.

2. MATERYAL VE YÖNTEM

Bu tezde, EMG veri setleri ile hareket ve cinsiyet sınıflandırma yapılmıştır. Bu hedef doğrultusunda EMG sinyallerini sınıflandırmak adına çeşitli yöntemler test edilmiştir. Bu yöntemler için zaman alanı, frekans alanı ve zaman-frekans alanı kullanılarak öznelilikler çıkartılmış ve sınıflandırma yapılmıştır.

2.1. Elektromiyografi Yapısı

Elektromiyografi (EMG), kasların kasılması için oluşan elektrik sinyalleridir. EMG sinyalleri, İnsan-Bilgisayar Etkileşimi, protez uzuvların kontrolü gibi pek çok alanda kullanılmaktadır. Kas etkileşimi hakkında bilgi edinilebilen EMG sinyalleri, deri altı ve yüzey EMG olarak ikiye ayrılmaktadır. Deri altı EMG sinyalleri, deri altına nüfuz eden iğne elektrotlar ile toplanmaktadır (Zhang, Chen, Li, Lantz, Wang ve Yang, 2011). Yüzey EMG sinyallerini elde etmek için ise deri altına nüfuz etme ihtiyacı olmadan, deri üstüne yerleştirilen sensörler kullanılabilmektedir (Hu ve diğerleri, 2018). Bu çalışmada kullanılan EMG verileri yüzey EMG sinyallerinden oluşmaktadır. Ön kol kas grubundan veri toplamak üzere geliştirilen bir ürün olan Myo Armband isimli cihazdan toplanmış olan veriler bu çalışma kapsamında kullanılmaktadır.

2.2. Thalmic Labs MyoArmband

MyoArmband, Thalmic Labs tarafından 2014 yılında tanıtılan, bünyesinde barındırdığı 8 EMG sensörü ve 9 açılı Atalet Ölçüm Birimi (Inertial Measurement Unit, IMU) ile el kol hareketlerini tanıyan bir cihazdır. Kullanıcılar Resim 2.1.'de gösterilen MyoArmband isimli cihazı dirseklerinin altına denk düşecek ön kol bölgesine giyerek el kol hareketleri ile insan-bilgisayar etkileşimi sağlayabilmektedirler.



Resim 2.1. Thalmic Lab MyoArmband Cihazı (İnternet, 2015)

MyoArmband, kendi yazılımı ile beş temel hareketi tanıyabilmektedir. Bu hareketler eli sola çevirmek, sağa çevirmek, yumruk, parmaklar açık, parmakların çift dokunması ve son olarak da dinlenme hareketleridir (Rawat, Vats ve Kumar, 2016). Cihaz, 200Hz örnekleme oranı ile aldığı EMG verilerini bilgisayara Bluetooth yoluyla 8-bitlik Analog-Dijital Dönüştürücü (Analog to Digital Converter, ADC) ile aktarmaktadır (Benalcázar ve diğerleri, 2017). Ham haldeki EMG verileri, dijital formatlı verilere 8-bitlik ADC ile iletip, -128 ile +127 arasında bir değere dönüştürür (Sosin, Kudenko ve Shpilman, 2018).

2.3. Veri Setleri

Bu tezde iki farklı sEMG veri seti kullanılmıştır. Veri setlerinin ilki Kaggle platformunda paylaşılmış olan veri setidir (İnternet, 2018a). İlgili veri seti ile ilgili açıklama bir sonraki bölümde verilmiştir. Diğer veri seti ise tez kapsamında Thalmic Labs şirketinin üretmiş olduğu MyoArmband isimli cihaz kullanılarak hazırlanmıştır.

2.3.1. Veri Seti 1 (Electromyography(EMG) dataset)

Bu tezin ilk aşamasında topluluğa açık olarak Kaggle platformunda paylaşılan bir sEMG veri seti kullanılmıştır (İnternet, 2018a).

Veri seti 10 katılımcıdan alınan 7 farklı parmak hareketini içermektedir. Katılımcıların ön kol bölgelerine MyoArmband cihazını giydirilmiş ve baş parmak, işaret parmağı, orta parmak, yüzük parmağı, serçe parmak, zafer işareti ve dinlenme haline ait hareketlerin sEMG kayıtları alınmıştır. Katılımcılardan her hareketi 20-30 kez tekrarlamaları istenmiş ve hareket geçişlerinde 1 saniyelik duraklama yapılmıştır (Naseer, Ali, Ahmed, Iftikhar, Khan ve Nazeer, 2018).


2.3.2. Veri Seti 2 (Özgün sEMG veri seti)

Tez kapsamında, sEMG sinyalleri içeren özgün veri seti oluşturulup bu veri seti üzerinde sınıflandırma işlemleri yapılmıştır. Veri setini oluşturmak için Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Bilimsel Araştırmalar Etik Kurulu'ndan 15091.R1-15722 etik onay numarası ile etik izin alınmıştır. Veri seti toplama sürecine yaşları 22 ve 45 arasında değişen, sağ elini kullanan, bilinen herhangi bir kas yaralanması olmayan, nörolojik veya fizyolojik hastalığı bulunmayan ve temel kol hareketleri yapabilen 20 kişi katılmıştır. Katılımcıların cinsiyetlerinin eşit dağılmasına özen gösterilmiş, 10 erkek ve 10 kadın katılımcı veri toplama sürecine dahil edilmiştir. Katılımcıların sEMG verilerinin kaydedilme sürecine ait örnek bir görsel Resim 2.2.'de gösterilmektedir.



Resim 2.2. Katılımcılardan veri alınma sürecine dair örnek görsel

sEMG verileri, myo-python isimli bir Python kütüphanesi kullanılarak elde edilmiştir (İnternet, 2018b). Katılımcılardan MyoArmband'ı ön kol bölgelerine giymiş vaziyette kendilerine söylenen cümleleri tekrarlı şekilde yazmaları istenmiştir. 8 kanaldan elde edilen sEMG sinyalleri için bir örnek Şekil 2.1.'de gösterilmektedir.



Şekil 2.1. MyoArmband isimli cihazdan alınan 8 kanal sEMG verileri

Katılımcılardan 12 cümleyi tekrarlı şekilde yazmaları istenmiştir. Her cümle 10 kez tekrar edilmiş, tekrarlar ayrı ayrı kaydedilmiştir. Her tekrar için katılımcıların cinsiyeti, katılımcı sıra numarası, yazılan cümle ve kaçınıcı tekrar olduğu veri kayıt sürecinde etiketlenmiştir. Tablodan da görüleceği gibi cümleler 2 veya 3 kelimedenden oluşmaktadır. Bazı cümlelerin

başlangıcında veya sonunda aynı kelimeler bilinçli olarak tekrarlanmıştır. Cümleler aynı kelimelere sahip olsalar da birbirlerinden farklıdır. Cümle listesi Çizelge 2.1.’de gösterilmiştir.

Çizelge 2.1. Katılımcılardan yazmaları istenen kelimelerin listesi

apple juice	computer engineering
electrical engineering	civil engineering
go to left	go to right
hatay İskenderun	banana bread
smart phone	basketball court
study session	index finger

2.4. Makine Öğrenmesi


Makine öğrenmesi, istatistiksel modelleri içeren çeşitli algoritmaları kapsayan, mevcut verileri baz alarak tahmin veya kararlarda bulunan tasarımlardır.

Makine öğrenmesinin alt dalları denetimli ve denetimsiz öğrenmedir. Denetimli öğrenme (Supervised Learning), sistemin girdi ve çıktı çiftlerini kullanarak oluşturduğu bir öğrenme türüdür. Bu tezde kullanılan geleneksel makine öğrenmesi yöntemlerinin hepsi denetimli öğrenme yöntemidir.

2.4.1. k-En yakın komşu (k-Nearest neighbor, kNN)

k-En Yakın Komşu (k-Nearest Neighbor, kNN) algoritması, sınıflandırma ve regresyon problemleri için kullanılan bir denetimli öğrenme algoritmasıdır. Sınıflandırma süreci, yeni verinin özniteliklerinin incelenmesi ve yeni veriyi önceden tanımlanmış sınıflardan birine atama şeklinde ilerlemektedir. kNN algoritması, sınıflandıracağı verinin öğrenme kümesinde bulunan veriler ile benzerliğini hesaplayıp en yakın olduğu “k” adet komşu verinin sınıfına göre veriyi ilgili sınıfa atamaktadır (Öztürk, 2004).

Şekil 2.2.’de, mor daireler bir sınıfı, mavi daireler ise diğer sınıfı göstermektedir. Yeşil daire sınıflandırılmak istenen veri iken, iç daire en yakın 3 komşuyu, dış daire ise en yakın 7 komşuyu göstermektedir. $k=3$ durumu için sınıflandırılmak istenen veri Y sınıfına ait olurken, $k=7$ durumu için veri X sınıfına ait olmaktadır çünkü en yakın komşu adedinde k değiştiğinde ağırlıklı sınıf değişmektedir.



Şekil 2.2. kNN için k=3 ve k=7 için örnek sınıflandırma

kNN algoritmasında en yakın komşuların seçilmesi sürecinde çeşitli mesafe ölçüm yöntemleri kullanılabilmektedir. Ölçüm metrikleri en yakın sayılacak komşuların tespit edilmesini etkileyeceği için kNN algoritmasının performansında etkin bir rol oynamaktadır. Mesafe ölçümü için en sık kullanılan yöntem Öklid mesafesidir. kNN algoritmasında, iki veri arasındaki mesafe Öklid mesafesi ile ölçülürken Eş. 2.1. kullanılmaktadır (Öztürk, 2004);

$$mesafe(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2}. \quad (2.1)$$

Yukardaki denklemde, X_1 ve X_2 mesafesi hesaplanan çok boyutlu iki veridir. Formülde, iki verinin her boyutundaki değerler arasındaki farkın karesi alınarak toplanır ve mesafe sonucu elde edilmektedir. Mesafe ölçümleri yapıldıktan sonra en yakın k adet veriyi bulmak için Eş. 2.2. kullanılmakta ve veri en yakın sınıfa atanmaktadır.

$$y = \arg \max_{c_j} \sum_{i=1}^k I(y_i = j) \quad (2.2)$$

Eş. 2.2.'de k adet en yakın komşu için gösterge fonksiyonunun argümanı doğru ise 1, değil ise 0 değeri döndürülmektedir.

2.4.2. Destek vektör makineleri (support vector machines, SVM)

Destek Vektör Makineleri (Support Vector Machines, SVM), çekirdek tabanlı bir makine öğrenmesi algoritmasıdır (Köklü ve Özkan, 2020). kNN algoritması gibi, sınıflandırma ve

regresyon problemlerinde sıklıkla kullanılmaktadır. Başlangıcında iki sınıflı veriler için tasarlanan SVM algoritması, süreç içerisinde geliştirilerek çok sınıflı ve doğrusal olmayan problemler için de uygulanmaya başlanmıştır.

SVM algoritmasının, iki sınıflı bir problem için lineer çözüm modeli şu şekilde gösterilmektedir;


$$y(x) = w^T \varphi(x) + b \quad (2.3)$$

burada, $\varphi(x)$ düzenlenmiş öznitelik uzayının dönüşümünü, b ise sabit kayma terimini göstermektedir (Bishop, 2006).

SVM algoritması, n-boyutlu bir hiper düzlem ile eğitim verisini iki ayrı sınıfa bölmeyi hedeflemektedir. Hiper düzlemin, ayrışan sınıf sınırlarına eşit uzaklıkta olması beklenmektedir (Öztürk, 2004).

2.4.3. Karar ağaçları (Decision trees, DT)


Karar ağaçları (Decision Trees, DT), sınıflandırma ve regresyon problemlerinin çözümü için kullanılan denetimli makine öğrenmesi algoritmalarından biridir. DT algoritması, verilerin öznitelikleri için yinelemeli, ağaç benzeri bir yapı oluşturulmaktadır. Yinelemeli oluşan ağaçlar hiyerarşik bir yapıdadır (Kavzoğlu ve Çölkesen, 2010). Ağaçların yapısı kök düğüm, dallar, iç düğümler ve yaprak düğümlerden oluşmaktadır (Karadağ, 2023). Karar ağaçlarının yapısı Şekil 2.3.'te gösterilmiştir.



Şekil 2.3. Karar ağacı

2.4.4. Rastgele orman (Random Forest, RF)

Rastgele Orman (Random Forest, RF) algoritması, biz dizi karar ağacından oluşan, ağaçların verdiği sonuçları ile tahmin başarımını artırmak için kullanan bir yapıya sahip denetimli makine öğrenme tekniğidir. Rastgele Orman yapısı Şekil 2.4.'de gösterilmiştir.



Şekil 2.4. Rastgele orman

RF algoritması, her ağacın tahminini alır, ağaçların tahminlerinden oy çokluğu yöntemi ile seçilen kararı da tahmin olarak geri döndürmektedir. DT algoritmasından farkı ise tüm ağaçları aynı veriler ile beslemek yerine verileri bölerek farklı ağaçların bölünmüş verileri kullanarak karar vermesini sağlamasıdır (Kütük, 2024).

2.5. Derin Öğrenme

Derin öğrenme, verilerin içerdikleri tanımlayıcı bilgileri farklı katmanlarda tespit etmek üzere geliştirilmiş bir yöntemdir. Tanımlayıcı bilgilerin tespitinde yapay sinir ağları kullanılmaktadır. Yapay sinir ağları, insan beyninde bulunan sinir ağları ve nöronların matematiksel olarak modellenmesi fikri ile ortaya çıkmıştır. Nasıl ki insanlar da bir veriyi çeşitli tanımlayıcılar sayesinde tespit edip tanır ve gelecekte hatırlayabilirse, yapay sinir ağları da benzer şekilde tespit ettiği tanımlayıcı bilgileri kullanarak verileri tanımlayabilmekte ve benzer verilerin tanımladığı bilgilerden hangileri ile örtüştüğünü anlayıp tespit edebilmektedir.

2.5.1. Yapay sinir ağları


ANN, beyindeki sinir hücrelerinin biyolojik işleme şekillerinden ilham alınarak oluşturulmuş matematiksel yapılardır. ANN, düğümleri birbirlerine bağlayıp nöronları simüle etmeye çalışmakta ve üç ana katmandan meydana gelmektedir. Bu katmanlar, giriş katmanı, gizli katmanlar ve çıkış katmanıdır. Giriş katmanı veriyi dış dünyadan almaktan çıkış katmanı ise çıktıyı (tahmini) üretmekten sorumludur. Bahsedilen akışın gerçekleştirilebilmesi için gizli katmanlar verileri işler, bu sebeple gizli katmanlar ağıın öğrenme becerisinde önemli etkileri olan bileşenlerdir. Nöronlar, kendilerine gelen veriyi ağırlıkla çarpıp aktivasyon fonksiyonu ile bir çıktı üretir (LeCun, Bengio ve Hinton, 2015).

ANN, öğrenme süreci boyunca çarpım yapılan ağırlıkları ayarlayarak doğru tahmin yapmayı hedeflemektedir. Bu hedef doğrultusunda optimizasyon yöntemleri kullanılmaktadır. Ağırlıkların doğru tahmin yapabilmesi için ayarlanması, hata çıktısını en aza indirmek amacıyla yapılmaktadır. Hata çıktısı, hata fonksiyonu ile hesaplanmakta ve tahmin ile gerçek sonuç arasındaki fark ölçülmektedir. Hata fonksiyonları ile ayarlanan ağırlıklar sonuçların daha yüksek başarımla, daha doğru sonuçlara ulaşabilmesini sağlamaktadır. Bahsedilen süreç tekrarlı şekilde devam etmektedir (Rumelhart, Hinton ve Williams, 1986).

2.5.2. Evrişimsel sinir ağları (convolutional neural networks – CNN)

Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNN), insanların görsel becerilerinden, görüntüyü anlamlandırma sistemlerinden esinlenilerek geliştirilmiş ANN tabanlı bir makine öğrenmesi yaklaşımıdır (Gao, Li, Loomes ve Wang, 2017).

CNN, veriyi anlamlı hale getirebilmek adına çeşitli katmanlar kullanmaktadır. Bu katmanlar yerel özelliklerin tanınması için kullanılan evrişimsel (convolutional) katmanlar, karar verme sürecinde genelleme becerisini güçlendirmek için kullanılan havuzlama (pooling) katmanı ve çıkartılan özellikleri birleştirerek sınıflandırma yapmak için kullanılan Tam Bağlantılı (fully connected) katmanlardır (Karadağ, 2023). Evrişimsel Sinir Ağları yapısı Şekil 2.5.'de gösterilmiştir.



Şekil 2.5. Evrişimsel sinir ağları

Evriřim katmanı (convolutional layer)

Evriřim Katmanı (Convolutional Layer), özelliklerin tanınması için ağırlık matrislerinden oluşan filtreleri uygulayarak özellik haritalarının elde edilmesini sağlamaktadır. Filtreler girdi üzerinde hareket ederek yerel özelliklerin tanınmasını sağlamaya çalışmaktadır. Yerel özelliklerin tanınmasının isteneceğı alanın boyutuna ve hareket edeceği miktara göre filtrenin boyutu (size) ve adımı (stride) değişmektedir (Bayram, 2020). Aynı zamanda, süreç esnasında veri boyutunun küçülmesinin önlenmesi ve istenen boyutta verinin bir sonraki katmana iletilebilmesi için filtre ile dolgu (padding) kullanılmaktadır. Adım parametresi, girdi verisi üzerinde hareket edecek olan filtrenin hareket miktarını belirleyen parametredir. Dolgu parametresi ise girdi verisine filtre uygulandıktan sonra istenen girdinin boyutunun korunabilmesi için kullanılmaktadır (Karadağ, 2023).

Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanı, evriřimsel katmanların arasına eklenip katmanlardan gelen verinin boyutunu küçültmek için kullanılmaktadır. Katmanın amacı, modelin ezber durumuna geçmesini önlemek ve model öğrenme hızını arttırmaktır (Gürsoy, 2025). Havuzlama katmanında çoğunlukla Maksimum Havuzlama veya Ortalama Havuzlama yöntemleri kullanılmaktadır. Maksimum havuzlama, belirlenen bölgedeki en yüksek değere sahip veriyi alırken, ortalama havuzlama bölgenin ortalama değerini almaktadır.

Tam Bağlantı Katmanı (Fully Connected Layer)

Tam bağlantı katmanı, düzleştirilmiş öznitelik matrisleridir. Her nöron bir önceki katmanın nöronları ile bağlantılıdır. Her nöron çıktısı, önceki katmanın nöronlarının ağırlıklı toplamı ve biasları ile hesaplanmaktadır.

2.6. Ön İşleme

EMG sinyallerinden elde edilen verilerin analiz edilip makine öğrenmesi algoritmalarında uygulanabilmesi için bu veriler hem ham halde hem de çeşitli işlemlerden geçirilerek kullanılmaktadır. Öznitelik çıkartma işlemi öncesinde, ham veriler bir ön işleme tabi tutulabilmektedir. Bu işlem, verilerin analiz edilmesi ya da makine öğrenmesi algoritmalarında kullanılması tercih edilen hale gelmesini sağlamak için yapılmaktadır. Ön işleme, verileri hatalardan arındırmak, gürültüyü azaltmak veya tespit etmek, kısacası düzenli hale getirmek için kullanılmaktadır.

2.6.1. Dalgacık dönüşümü (wavelet transform, WT)

Dalgacık Dönüşümü (Wavelet Transform, WT), bir sinyalin farklı frekans bileşenlerine ayrılması için kullanılan bir yöntemdir. WT yönteminin Fourier dönüşümü gibi geleneksel yöntemlerden farkı, zaman ve frekans alanlarında aynı anda analiz yapılmasını sağlamasıdır. Fourier dönüşümü, sinyali sinüs ve kosinüs bileşenlerine böler. Dalgacık dönüşümünde ise bileşenlerine bölünen sinyal, seçilen ana dalgacığın ölçeklenmiş ve kaydırılmış dalgacıklarıdır (Sparto, Parnianpour, Barria ve Jagadeesh, 2000).

2.6.2. Ayırık dalgacık dönüşümü (discrete wavelet transform, DWT)

Ayrık dalgacık dönüşümünde, sinyal tek bir parça olarak değil ayrı zaman dilimleri olarak alınmakta ve dalgacık dönüşümleri bu zaman diliminden alınan sinyal üzerinde gerçekleştirilmektedir (Zhang, Wang ve Han, 2010).

2.7. Öznitelik Çıkarımı

Ham verilerin anlamlı hale gelebilmesi ve makine öğrenmesi algoritmalarında kullanılabilmesi için ham verilerin taşıdıkları özelliklerin çıkartılması gerekmektedir. Ham verilerin taşıdıkları özelliklerin çıkartılması işlemine öznitelik çıkarımı denilmektedir.

EMG gibi zaman alanında bulunan verilerden zaman alanı ve frekans alanı öznitelikleri çıkartılabilir. Bu tezde çeşitli çalışmalar için hem zaman alanı hem de frekans alanı öznitelikleri kullanılmıştır.

2.7.1. Zaman alanı öznitelikleri

Karekök ortalama (root mean square, RMS)

Örneklenen değerlerin karekök ortalamalarının elde edilmesi, zaman alanından çıkartılan özniteliklerden birisidir ve Eş. 2.4.'de gösterildiği gibi hesaplanmaktadır,

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (2.4)$$

x , i indeksindeki örneklenen voltaj değerini, N ise pencere büyüklüğünü göstermektedir (Laliharatne, Hayashi, Teramoto ve Kiguchi, 2012).

Eğim işaret değişikliği (slope sign change, SSC)

EMG sinyalinin işaret değişimi sayısı, zaman alanından elde edilen özniteliklerden birisidir ve Eş. 2.5.'de gösterildiği gibi hesaplanmaktadır (Phinyomark, Phukpattaranont ve Limsakul, 2012),

$$SSC = \sum_{n=2}^{N-1} [f[(X_n - X_{n+1}) \times (X_n - X_{n-1})]], \quad (2.5)$$

$$f(x) = \begin{cases} 1, & x < threshold \\ 0, & otherwise \end{cases}.$$

Dalga boyutu (wavelength, wl)

EMG sinyalinin karmaşıklığını gösteren öznitelik Dalga Boyutu (Wavelength, WL) özniteliğidir, Eş. 2.6'da gösterildiği şekilde EMG sinyalinin zaman içindeki toplam uzunluğu hesaplanarak elde edilmektedir (Phinyomark, Phukpattaranont ve Limsakul, 2012).

$$WL = \sum_{n=1}^{N-1} |x_{n+1} - x_n| \quad (2.6)$$

Ortalama mutlak değer (mean absolute valute, MAV)

EMG sinyalinin belirli bir zaman içindeki ortalama mutlak voltaj değeri Eş. 2.7. ile elde edilmektedir (Phinyomark, Phukpattaranont ve Limsakul, 2012),

$$MAV = \frac{1}{N} \sum_{n=1}^{N-1} |x_n|. \quad (2.7)$$

Ortalama genlik değişimi (average amplitude change, AAC)

Ortalama genlik değişimi olarak adlandırılan dalga boyu uzunluğunun ortalananmış değeri aşağıdaki Eş. 2.8. ile hesaplanmaktadır (Phinyomark, Phukpattaranont ve Limsakul, 2012),

$$AAC = \frac{1}{N} \sum_{n=1}^{N-1} |x_{n+1} - x_n|. \quad (2.8)$$

Maksimum Fraktal Uzunluğu (Maximum fractal length, MFL)

Düşük seviye kas aktivitelerinin ölçümü için maksimum fraktal uzunluk özneliği Eş. 2.9. ile elde edilerek kullanılmaktadır (Phinyomark, Phukpattaranont ve Limsakul, 2012),

$$MFL = \log_{10} \left(\sqrt{\sum_n^{N-1} x_{n+1} - x_n^2} \right). \quad (2.9)$$

Ortalama kuvvet (average power, AP)

Enerji dağılımını hesaplamak için kullanılan ve sonucunda istatistiksel bir öznelilik elde edilen ortalama kuvvet özneliği Eş. 2.10. ile hesaplanmaktadır (Too, Abdullah, Mohd Saad ve Tee, 2019),

$$AP = \frac{1}{N} \sum_{n=1}^N x_n^2. \quad (2.10)$$

Sıfır geçişi (zero crossing, ZC)

Zaman alanında, frekans alanı hakkında yaklaşık bir tahmin yapmak için sıfır geçişi özneliği kullanılır. Bu öznelilik Eş. 2. 11. kullanılarak elde edilmektedir (Li, Shi ve Yu, 2021),

$$ZC = \sum_n^{N-1} \text{sign}(x_n, x_{n+1}) \quad (2.11)$$

$$\text{sign}(s_n, s_{n+1}) = \begin{cases} 0, & s_n \times s_{n+1} > 0 \\ 1, & \text{otherwise} \end{cases}.$$

Varyans (Variance, VAR)

Varyans, EMG sinyalinin gücü baz alınarak Eş. 2. 12. ile hesaplanır (Altın ve Er, 2016).

$$VAR = \frac{1}{N-1} \sum_{n=1}^N x_n^2 \quad (2.12)$$

Standart sapma (standard deviation, STD)

Sinyaldeki parazitler standart sapma ile ifade edilip Eş. 2. 13. ile hesaplanmaktadır. Sinyalin yayılması, bireysel değerlerin ortalama değer ile kıyaslanması sonucu elde edilmektedir (Altın ve Er, 2016).

$$STD = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2} \quad (2.13)$$

2.7.2. Frekans alanı öznitelikleri

Ortalama güç frekansı (mean power frequency, MPF)

EMG güç spektrumunun ortalama güç değerinin Eş. 2.14. ile hesaplanması sonrasında elde edilen öznitelik Ortalama Güç Frekansı (Mean Power Frequency, MPF) olarak adlandırılmaktadır (Phinyomark, Phukpattaranont ve Limsakul, 2012).

$$MPF = \frac{\sum_{j=1}^M P_j}{M} \quad (2.14)$$

Burada, P güç spektral yoğunluğunu, M ise örnek sayısıdır.

Toplam güç (total power, TTP)

EMG güç spektrum değerlerinin toplamından elde edilen özniteliğe Toplam Güç denmekte ve Eş. 2.15. ile hesaplanmaktadır (Phinyomark, Phukpattaranont ve Limsakul, 2012).

$$TP = \sum_{j=1}^M P_j \quad (2.15)$$

Burada, P güç spektral yoğunluğunu, M ise örnek sayısıdır.

Ortalama frekans (mean frequency, MNF)

EMG spektrumun çarpımının spektrum yoğunluk toplamına bölünmesiyle elde edilen Ortalama Frekans (Mean Frequency, MNF) özniteliği Eş. 2.16. ile elde edilmektedir (Phinyomark, Phukpattaranont ve Limsakul, 2012).

$$MNF = \frac{\sum_{j=1}^M f_i P_j}{\sum_{j=1}^M P_j} \quad (2.16)$$

Burada, M örnek sayısını, P güç spektrum yoğunluğunu, f ise frekans bileşenini göstermektedir.

Medyan frekans (median frequency, MDF)

Medyan frekans (Median Frequency, MDF), güç yoğunluk spektrumunu iki eş bölgeye bölen frekansa denmekte ve Eş. 2. 17. ile gösterilmektedir (Abdelouahad, Belkhou, Jbari ve Ballarbi, 2018).

$$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^N P_j = \frac{1}{2} \sum_{j=1}^N P_j \quad (2.17)$$

Burada, MDF medyan frekansı, N örnek sayısını, P ise güç spektrum yoğunluğunu göstermektedir.

Frekans oranı (frequency ratio, FR)

Eş. 2.18. ile hesaplanan frekans oranı, EMG sinyallerinin düşük ve yüksek frekans bileşenlerinin oranına dayanarak kasların kasılma ve gevşeme durumlarını ayırt etmekte kullanılan bir özneliktir (Phinyomark, Phukpattaranont ve Limsakul, 2012).


$$FR = \frac{\sum_{j=LLC}^{ULC} P_j}{\sum_{j=LHC}^{UHC} P_j} \quad (2.18)$$

Burada, Üst Kesim Frekansı (Upper Limit Cutoff, ULC) ve Alt Kesim Frekansı (Lower Limit Cutoff, LLC) düşük frekans bandı için üst ve alt kesim frekans değerleri iken, Üst Harmonik Bileşeni (Upper Harmonic Component, UHC) ve Alt Harmonik Bileşeni (Lower Harmonic Component, LHC) de yüksek frekans bandı için üst ve alt kesim frekans değerlerini göstermektedir.

2.7.3. Pencereleme ve kayan pencereler

Çoklu zaman serisi verileri, tek bir zaman serisi verisinden kayan pencereler kullanılarak elde edilebilmektedir. Zaman serisi verilerinin belirli bir aralığındaki verilerin alınmasına pencereleme tekniği denilmektedir (Yu, Zhu, Li ve Wan, 2014).

Pencereleme tekniği, belirli limitteki verinin kullanılmasıdır. Belirli zaman serisi kısmını farklı pencerelerin ortak kullanmasına ise üst üste binen pencereler denmektedir. Şekil 2.6'da üst üste binen kayan pencere örneği gösterilmektedir.



Şekil 2.6. Üst üste binen kayan pencere örneği

Bu tezde, üst-üste binen ve binmeyen pencereler kullanılarak sonuçlar elde edilmiş ve kıyaslanmıştır. Yapılan çalışmalar ve elde edilen sonuçlar Araştırma Bulguları kısmında tartışılacaktır.

2.8. Optimizasyon Algoritmaları

Optimizasyon, belirli aralıktaki sayısal değerlerin en uygununu seçilmesi ile karmaşık problemlerin çözümünün bir amaç fonksiyonu ile çözülmesidir. Optimizasyonun amacı en az maliyet ile en yüksek kazancın elde edilmesinin sağlanmasıdır. Probleme uygun şekilde önceden belirlenen sınır değerlerine göre, problemin çözümü için kullanılacak parametrelerin en uygun değerlerinin bulunması amaçlanmaktadır (Özsağlam ve Çunkaş, 2008).

Optimizasyonda ilk olarak problemi etkileyen değişkenler bulunarak ilgili değişkenler için sınır değerleri belirlenir. Ardından, bir amaç fonksiyonu ile en yüksek performansın en az maliyet ile elde edilmesi sağlanır.

2.8.1. Parçacık sürü optimizasyonu (particle swarm optimization, PSO)

Parçacık Sürü Optimizasyonu, sürülerin beslenme ile ilgili sosyal tepkilerinden ilham alınarak geliştirilen popülasyon tabanlı bir optimizasyon algoritmasıdır (Kennedy ve Eberhart, 1995). Algoritmanın çalışma mantığı sürülerin gerçek hayat tepkilerinde olduğu üzere sürü içerisindeki bireylerin tümünün besin kaynaklarının yerini bilmemesi, sürü içerisinde besin kaynağına en yakın bireyi takip etme eğilimleri üzerine kurulmuştur (İşçimen, 2024).

Sürüdeki bireylerin her biri yiyeceğe en yakın birey olabilme potansiyeline sahiptir. Bu sebeple, arama uzayında optimize edilecek olan problemin çözümüne de en yakın olma potansiyelleri vardır.

Sürüdeki her parçacığın, bireyin, üç temel özelliği vardır. Bunlar konum, hız ve maliyet değeridir. Algoritma çalışmaya başlarken parçacıkların başlangıç hızları önceden belirlenmiş bir aralıkta rastgele seçilir. Her döngüde parçacıklar kendi en iyi konumları, sürü içerisinde seçilen en iyi konum ve hızlarına bağlı bir doğrultuda hareket eder. Parçacıkların konumu, arama uzayında mevcut yerleridir, en iyi konum ise arama uzayında optimum sonucu vermekte olan pozisyonudur. Her iterasyonun ardından parçacıklar kendi en iyi konumlarını ve sürünün en iyi konumunu belirlemiş olurlar. Bu konumlar belirlendikten sonra, parçacıklar kendi konumlarını ve mevcut hızlarını Eş. 2.19 ve Eş. 2.20 ile elde edip sürünün kalanına bildirirler (Altunkol, 2022).

$$X_{k+1}^i = X_k^i + V_{k+1}^i \quad (2.19)$$

$$V_{k+1}^i = w V_k^i + c_1 r_1 (P_k^i - X_k^i) + c_2 r_2 (P_k^g - X_k^i) \quad (2.20)$$

Yukarıdaki iki eşitlikte, X konumu, V ise hızı temsil etmektedir. k , iterasyon indeksini, i parçacık indeksini gösterirken c_1 ve c_2 her parçacığın bireysel öğrenme ve sosyal parametrelerini yani bilişsel ve sosyal parametreleri göstermektedir. r_1 ve r_2 değerleri ise rastgele üretilen değerlerdir. Eşitliklerde gösterilen P_k^i değeri parçacığın kendi en iyi konumunu, P_k^g ise sürünün en iyi konumunu gösteren parçacığın konumunu temsil etmektedir (Alsabaawi, 2020).

2.8.2. Ağaç-tohum algoritması (tree-seed algorithm, TSA)


Ağaç-Tohum Algoritması (Tree-Seed Algorithm, TSA), optimizasyon problemlerinin çözümü için önerilen, ağaçların ve tohumların doğal ilişkilerinden esinlenerek önerilen bir optimizasyon algoritmasıdır (Kıran, 2015).

Ağaç-Tohum Algoritmasının çalışmasında ilk aşamada problemi çözmek için başlangıç sonuçları üretilir, bu sonuçlar ağaçlar olarak düşünebilir. Her ağaç için tohumlar üretilir. Ağaçların tohumları içerisinde o ağaç için en iyi tohum seçilir. Ağaçlar ve tohumların arama uzayındaki konumları kıyaslanır. Eğer tohumun arama uzayındaki konumu ağacın konumundan daha iyi ise, ağacın konumu artık en iyi tohumun konumu olarak belirlenir ve tohum ağacın yerini almış olur. Algoritmanın çalışmasının arkasındaki mantık, en iyi ağaç konumunu belirlemektir. En iyi ağaç konumu ise, optimum çözüm parametrelerini


göstermektedir. Ağaçların konumları da kendi aralarında kıyaslanır ve konumu en iyi olan ağaç en iyi ağaç olarak seçilir. Bu döngü algoritma çalıştıkça devam eder (Çınar, 2016).

En iyi konumu bulmak için arama uzayındaki arayışın genişletileceği ya da daraltılacağına karar vermek için arama eğilimi (search tendency, ST) olarak isimlendirilen bir parametre kullanılır. Arama Eğilimi parametresine göre, algoritma keşfetme ya da faydalanma kararını vermektedir. Keşfetme ve faydalanma algoritmanın arama süreci için temel unsurlardır. Keşfetme, arama uzayının ağaç ile rastgele seçilecek bir ağaç arasına çekilmesidir. Faydalanma ise aramanın ağacın yakınında bulunan ağaçlardan bir tanesinin seçilmesi ve bu ağaç ile ağaçlar arasında en iyi konuma sahip ağacın arasında bir bölgeye çekilmesidir. Seçilen rastgele ağaç komşu olarak isimlendirilebilir (Karakul ve Gökçen, 2024).

Şekil 2.7’de Ağaç-Tohum algoritmasının ilk aşamasında uzayda oluşturan ağaçlar görselleştirilmiştir. Ağaçların konumları problemin muhtemel çözümlerinin uzayda dağılımını temsil etmektedir. Her ağacın konumu bir çözümü gösterir. Ağaçların konumları kendi aralarında kıyaslanarak en iyi konum bulunur ve o konuma sahip ağaç en iyi ağaç seçilir. En iyi ağacın konumu problemin mevcut en iyi çözümünü gösterir. Şekil 2.8’de ise kıyaslar sonucunda seçilen en iyi ağaç temsil edilmektedir.




Şekil 2.7. Ağaç-Tohum algoritması, ağaçların oluşturulması




Şekil 2.8. Ağaç-Tohum algoritması, en iyi ağacın seçilmesi

En iyi ağacın seçilmesinin ardından, her ağaç için tohum üretilir. Resim 2.9’da gösterildiği üzere, tohumların konumu ağacın farklı yerlerinde bulunur.




Resim 2.9. Ağaç-Tohum algoritması, ağaçların tohumlarının oluşturulması

Ağaçların tohumlarının üretilmesinin ardından, her ağaç için tohum kıyası yapılır. Ağacın tohumları kendi aralarında kıyaslanarak her ağaç için en iyi tohum konumu bulunur. Resim 2.10.’da her ağaç için belirlenen en iyi tohum gösterilmektedir. En iyi tohum konumu, problem çözümü için tohumlar arasında en iyi sonucu veren konumdur. En iyi tohumun bulunma sebebi, ağacın konumunun değişmesinin gerekip gerekmediğine karar verilmesi için muhtemelen bir konum seçilmesi gerekmesindendir.



Şekil 2.10. Ağaç-Tohum algoritması, ağaçların en iyi tohumlarının seçilmesi


Ağaçların tohumları arasında kıyas yapılmasının ardından her ağaç için en iyi tohum yani her ağaç için olası en iyi konum bulunmuş olur. Bu aşamanın ardından her ağacın konumu ile ağacın en iyi tohumu arasında kıyas yapılır. Eğer ağacın konumu en iyi tohumun konumundan daha iyi ise ağacın konumu değiştirilmez ve ağaç kendi yerinde kalır. Eğer en iyi tohumun konumu ağacın konumundan daha iyi ise yani en iyi tohum bağlı olduğu ağaçtan daha iyi çözüm buluyor ise en iyi tohum artık ağaç olur. Şekil 2.11.'de bu değişim gösterilmektedir.



Şekil 2.11. Ağaç-Tohum algoritması, ağaçların en iyi tohumları ile kıyaslanması sonucu

Yukarıdaki şekilde, en iyi tohumundan daha iyi konuma sahip ağaçlar için en iyi tohumlar bulanıklaştırılmıştır. En iyi tohumun ağaçtan daha iyi bir konuma sahip olduğu durumlar için ise ağaçlar bulanık gösterilmiştir.

Ağaçların en iyi tohumları ile kıyaslanmalarının ardından bazı tohumlar yukarıdaki görselde gösterildiği şekilde ağaç olurlar. Sonraki aşamalarda tohumlar, eski en iyi tohum olan ağacın çevresinde üretilir. Ağaçların en iyi tohumları ile kıyaslamalarının ardından değişen ağaç ve tohum konumları sonrasında tekrar en iyi ağaç konumu için ağaç konumları kıyaslanır. Yeni kıyasta en iyi tohumları tarafından konumları değiştirilen ağaç konumları kullanılmaz, kıyaslanacak olan ağaçlar en iyi tohumdan daha iyi konuma sahip olan ağaçlar ve ağaçlarından daha iyi sonuç vermiş olan en iyi tohumlardır. Şekil 2.12.'de bir sonraki arama sonucunda değişen en iyi ağaç gösterilmektedir.



Şekil 2.12. Ağaç-Tohum algoritması, iterasyon sonucu en iyi ağacın seçilmesi

Algoritmada ağaçlar için oluşturulacak tohumlar arama eğilimi parametresine göre aşağıdaki formüllerden biri seçilerek oluşturulur. Eğer araştırma parametresi rastgele üretilen sayıdan küçük ise Eş. 2. 21., büyük ise Eş. 2. 22. seçilir ve seçilen formül ile tohum oluşturulur (Aslan, Beskirli, Kodaz ve Kıran, 2018).

$$Seed_{i,j} = Tree_{i,j} + (Best_j - Tree_{r,j}) \times (rnd - 0.5) * 2 \quad (2.21)$$

$$Seed_{i,j} = Tree_{i,j} + (Tree_{i,j} - Tree_{r,j}) \times (rnd - 0.5) * 2 \quad (2.22)$$

Eşitliklerde, *Seed* tohumları, *Tree* ağaçları, *i* ağaç ve tohumun indeksini, *j* boyut indeksini göstermektedir. $Seed_{i,j}$ *i* nci ağaçtan üretilen *i* nci tohumun *j* indeksindeki boyutunu, $Best_j$ mevcut en iyi konumlu ağacın *j* indeksli boyutunu, *rnd* rastgele üretilmiş sayıyı, *r* rastgele seçilen ağacın indeksini göstermektedir.

2.9. Performans Çıktıları İçin Hesaplamalar

Makine öğrenmesi modellerinde, modelin performansının ölçülmesi için çeşitli metrikler kullanılmaktadır. Bu tezde kullanılan performans metrikleri doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F-1 skoru (F1-score) metrikleridir. Metriklerin yanı sıra, tahmin başarımını göstermek için karmaşıklık matrisi kullanılmakta ve karmaşıklık matrisi oluşturan değerler ile performans metrikleri ölçülmektedir.

Şekil 2.13.'te gösterilen karmaşıklık matrisi, verilerin içerisindeki gerçek sınıfları ve tahmin edilen sınıfın eşleşmesini göstermektedir.

		Gerçek Değerler	
		Pozitif	Negatif
Tahmin Değerleri	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 2.13. Karmaşıklık matrisi

Model tahminleri sonrası, gerçek değerler ve tahmin değerleri arasında oluşan bu eşleşme yani karmaşıklık matrisi, için hesaplanan Doğru-Pozitif (True Pozitif, TP), Yanlış Pozitif (False Positive, FP), Yanlış Negatif (False Negative, FN) ve Doğru Negatif (True Negative, TN) sayıları performans metriklerinin hesaplanmasında kullanılmaktadır.

TP: Sınıfa ait verilerin doğru şekilde ilgili sınıfa ait olarak tahmin edilen veri sayısı.

FP: Sınıfa ait olmayan fakat sınıfa ait olarak hatalı tahmin edilen veri sayısı.

FN: Sınıfa ait olan fakat sınıfa ait olarak hatalı tahmin edilmeyen veri sayısı.

TN: Sınıfa ait olmayan ve doğru şekilde sınıfa ait o değil olarak tahmin edilen veri sayısı.

2.9.1. Doğruluk (Accuracy)

Doğruluk değeri, sınıflandırma sonrasında başarılı olarak tahmin edilen veri sayısının toplam veriye oranı ile ifade edilmekte ve Eş. 2. 23. ile hesaplanmaktadır,

$$doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.23)$$

2.9.2. Hassasiyet (Precision)

Başarılı şekilde sınıfa ait olarak tahmin edilen değerlerin, sınıfa ait olarak tahmin edilen veri sayısına oranıdır. Eş. 2. 24 ile hesaplanmaktadır.

$$hassasiyet = \frac{TP}{TP + FP} \quad (2.24)$$

2.9.3. Duyarlılık (Recall)

Eş. 2. 25.'de gösterilen duyarlılık, sınıfa ait olan verilerin başarılı şekilde sınıfa ait olarak tahmin edilme oranıdır. Yani, sınıfa ait olarak başarılı tahmin edilmiş verilerin, başarılı tahmin edilen ve sınıfta olup da hatalı şekilde sınıfın dışında tahmin edilen verilere oranıdır.

$$duyarlılık = \frac{TP}{TP + FN} \quad (2.25)$$

2.9.4. F1-Skoru (F1-Score)

Duyarlılık ve hassasiyet metriklerinin sonuçlarının harmonik ortalamasının alınması ile iki metriğin dengeli, bütün bir veri sunmasını sağlar. Bu performans metriği Eş. 2. 26. ile hesaplanmaktadır.

$$f1Skor = 2 \times \frac{hassasiyet * duyarlılık}{hassasiyet + duyarlılık} \quad (2.26)$$

eşitliği ile hesaplarız.

3. ARAŞTIRMA BULGULARI

Bu tezde, iki farklı veri seti ile çalışmalar yapılmıştır. Her iki veri seti ile ilgili bilgiler önceki bölümlerde verilmiştir. İlk veri seti, topluluğun kullanımına açık bir sEMG veri setidir. Veri seti, 7 farklı el hareketi içermektedir. Bu hareketlerin 6 tanesi parmak hareketleridir. Bu sebeple, ilgili veri setinin kullanıldığı çalışmalarda parmakların hareketlerini sınıflandırmak adına yalnızca parmakların tekil olarak hareketi için kaydedilen veriler kullanılmıştır. Diğer sEMG veri seti ise tarafımızdan oluşturulan özgün olarak hazırlanan bir veri setidir. Özgün veri seti oluşturulurken katılımcılardan 12 cümleyi 10 kez yazmaları istenmiş, istenen cümle yazılırken katılımcıların önkol bölgelerinden sEMG sinyalleri kaydedilmiştir. Tezin ilerleyen bölümünde tez kapsamında yapılan bilimsel çalışmalara yer verilmiştir.

3.1. Emg Tabanlı Parmak Hareketi Tanıma ve Pencere Boyutu Karşılaştırması


Bu çalışmada, Kaggle platformunda topluluğun kullanımına açık şekilde paylaşılan veri seti kullanılmıştır (İnternet, 2018a). Veri seti, 7 el hareketini gerçekleştiren katılımcıların verilerini içermektedir. Hareketlerden 6 tanesi parmak hareketi (işaret parmağı, baş parmak, orta parmak, yüzük parmağı, serçe parmak ve dinlenme) iken, son hareket zafer işaretidir. Çalışmada tekil olarak hareket eden parmakların sınıflandırılmasına odaklanıldığı için 6 temel parmak hareketi çalışmaya dahil edilmiştir (Naseer ve diğerleri, 2018).

Veri setinden öznitelik çıkarımında 50, 200 ve 1000ms boyutunda pencerelerin kullanılmasının ve pencerelerde üst üste binme olmasının geleneksel makine öğrenmesi yöntemlerindeki etkilerinin neler olduğu ve sEMG verilerinin sınıflandırılma başarımına etkisi incelenmiştir. Görselde üst üste binen pencere örneği verilmiştir. Çıkarılan öznitelikler RMS, SSC, WL, MAE ve AAC öznitelikleridir. Elde edilen öznitelikler makine öğrenmesi algoritmalarında kullanılmadan önce min-max normalize yöntemi ile normalize edilmiştir.

Rastgele Orman ve Destek Vektör Makineleri kullanılarak yapılan sınıflandırmalarda, Rastgele Orman yönteminin sEMG sinyallerini sınıflamada Destek Vektör Makinelerine kıyasla daha yüksek başarımlarla sonuç verdiği görülmüştür. Elde edilen en yüksek başarımlar, üst üste binme metodu ile kullanılan 1000ms boyutlu pencerelerden çıkartılan özniteliklerle olmuş ve 96.30% doğruluk oranı elde edilmiştir.


Üst üste binme yönteminin kullanıldığı durum için 50ms lik kaydırma, diğer durumlar için ise pencere boyutu kadar kaydırma yapılmıştır. 50mslik kaydırma için 1000ms pencere boyutu kullanıldığı durumda peş peşe alınan iki örnek için 950mslik üst üste binme söz konusudur.

SVM ve RF algoritmaları belirlenen tüm pencere boyutlarından elde edilen öznelilikler ile uygulanmış ve sonuçları kıyaslanmıştır. Kıyaslama için grafik Şekil 3.1.'de gösterilmektedir.




Şekil 3.1. Pencere boyutlarına göre doğruluk oranı


Şekil 3.1.'deki grafikte farklı pencere boyutlarından çıkartılan özneliliklerin RF ve SVM algoritmalarında kullanılmalarının ardından elde edilen sınıflandırma başarımları gösterilmektedir. Şekilde de görüldüğü üzere, en düşük başarımlar her iki yöntem için de 50ms pencere kullanımı ile gerçekleşirken en yüksek başarımlar 1000ms pencerenin üst üste binme yöntemi ile kullanımı ile elde edilmiştir. SVM ve RF yöntemleri için en düşük başarımlar sırasıyla 35.59% ve 63.28% iken, en yüksek başarımlar 76.55% ve 96.30% olarak ölçülmüştür. Yapılan sınıflandırmaların başarımının gözlemlenmesi için karmaşıklık matrisleri çıkartılmıştır. Şekil 3.2.'de sırası ile RF ve SVM yöntemleri için en iyi ve en kötü başarımların veren denemelerin karmaşıklık matrisi gösterilmektedir.




Şekil 3.2. (a) En iyi sonucu veren RF



Şekil 3.2. (b) En kötü sonucu veren RF



Şekil 3.2. (c) En iyi sonucu veren SVM



Şekil 3.2. (d) En kötü sonucu veren SVM

Şekil 3.2. RF ve SVM için en iyi ve en kötü başarımların karmaşıklık matrisleri


Alınan sonuçlar açıkça göstermektedir ki, 1000ms pencere boyutunun üst üste binme yöntemi ile kullanılması ile elde edilen öznelilikler kullanılan EMG veri setinin sınıflandırma doğruluk başarımının en yüksek hale getirmektedir. Benzer şekilde, en düşük başarımları veren öznelilikler 50ms pencere boyutu kullanılması ile elde edilen öznelilikler olmuş ve çok fazla miktarda hatalı tahmin ile sonuçlanmıştır (Karakul ve Gökçen, 2023)

3.2. Dalgacık Dönüşümü Tabanlı Parmak Hareketi Tanıma

Bu çalışmada, Kaggle platformunda topluluğunda kullanımına açık şekilde paylaşılan ve bir önceki çalışmada da kullanılmış olan veri seti kullanılmıştır (İnternet, 2018a). Çalışmada frekans ve zaman alanlarından elde edilen öznitelikler birlikte kullanılmıştır. Frekans ve zaman alanlarında analiz yapılabilmesi için DWT yöntemi seçilmiştir. Bu çalışmada kullanılan veri setinde yapılan geçmiş çalışmalarda, dalgacık dönüşümü yönteminin denenmemiş olması sebebiyle, veri setinde dalgacık dönüşüm yöntemi ilk kez kullanılmıştır. Dalgacık dönüşümü için üç farklı dalgacık kullanılıp kıyaslanmıştır. Kullanılan dalgacıklar Symlet 4, Daubechies 4 ve Haar dalgacıklarıdır.

Symlet 4, Daubechies 4 ve Haar dalgacıkları ile DWT işlemi uygulanan veri setinden zaman ve frekans alanı öznitelikleri çıkartılmıştır. Tezin bir önceki aşamasında geleneksel makine öğrenmesi yöntemlerinden iki tanesi ile zaman alanı öznitelikleri kullanıldığı için, çalışmanın bu aşamasında DWT işlemi sonrasında elde edilen verilerden çıkartılan zaman ve frekans alanı öznitelikleri CNN modeli ile sınıflandırılmıştır. Çalışmanın amacı DWT işleminin kullanılan EMG veri setinin sınıflandırılmasına etkisini gözlemlenmesi, kullanılan dalgacıkların başarımlarının yapılmasıdır. Bu sebeple çalışmanın DWT işlemi sonrası elde edilen verilerden aynı öznitelikler çıkartılmış ve aynı mimari kullanılarak CNN modelleri eğitilmiştir. Çalışmada kullanılan zaman alanı öznitelikleri RMS, WL, MAV, VAR ve STD öznitelikleridir. Frekans alanı öznitelikleri ise MPF, TTP, MNF, MDF ve FR öznitelikleridir.

CNN modelinin mimarisinde katmanların çekirdek boyutları (Kernel size) 64'ten başlamış, 2'ye katlanarak katmanlar eklenmiştir. Her katman için adım değeri (stride) 1 olarak sabit tutulmuştur. 2. Katmanın ardından mimarinin tek Maksimum Havuzlama katmanı (max pool) 5x1 boyutunda eklenmiştir. Mimarinin şekli Şekil 3.3.'de gösterilmektedir. CNN modeli için kullanılan hiper-parametreler Çizelge 3.1.'de verilmiştir.



Şekil 3.3. CNN modelinin mimarisi

Yukarıdaki görselde mimarisi gösterilen modelin çalıştırıldığı ve en iyi sonucun elde edildiği hiper-parametreler Çizelge 3.1.'de gösterilmektedir. Her evrişim katmanı için aktivasyon fonksiyonu olarak Düzeltilmiş Doğrusal Birim (Rectified Linear Unit, ReLU) kullanılmış olup modelin karar için kullandığı aktivasyon fonksiyonu Sigmoid'dir. Sonuçlar Adam optimizasyonu, 0.001 öğrenme oranı ve 256 verilik yığın boyutu kullanılarak elde edilmiştir. Seyreltme için 50% oranı seçilmiştir.

Çizelge 3.1. CNN modelinin hiper-parametre tablosu


Her evrişim katmanı için aktivasyon fonksiyonu	ReLU
Seyreltme	50%
Optimizasyon	Adam
Öğrenme Oranı	0.001
Yığın Boyutu	256
Aktivasyon Fonksiyonu	Sigmoid

Symlet 4, Daubechies 4 ve Haar dalgacıkları kullanılarak veri setine uygulanan DWT sonrası elde edilen verilerden çıkartılan öznitelikler ile yukarıda mimarisi gösterilen model eğitilmiştir. Eğitim sonrası elde edilen model test için ayrılan veri setine uygulanmış ve sonuçlar test veri setinden elde edilen sonuçlar ile raporlanmıştır. Çizelge 3.2.'de görüleceği üzere, en iyi başarımlar Symlet 4 dalgacığı ile elde edilirken en kötü başarımlar Haar dalgacığı ile edilmiştir. Elde edilen sınıflandırma doğruluk başarımları Symlet 4, Daubechies ve Haar dalgacıkları için sırası ile 90.66%, 90.02% ve 91.56% olarak gözlemlenmiştir. Sınıflandırmaya ait diğer metrikler Çizelge 3.2.'de gösterilmiştir.


Çizelge 3.2. Dalgacıklardan elde edilen özniteliklerin başarımlar metrikleri

Dalgacık Adı	Doğruluk	Hassasiyet	F1 Skor	Duyarlılık
Daubechies 4	90.66	90.42	90.14	90.04
Haar	90.02	89.93	89.97	90.39
Symlet 4	91.56	91.30	91.44	91.69


Symlet 4, Daubechies 4 ve Haar dalgacıkları için karmaşıklık matrisleri Şekil 3.4.'de verilmiştir.



Şekil 3.4 (a). Symlet 4



Şekil 3.4 (b). Daubechies 4



Resim 3.4 (c). Haar

Şekil 3.4. Dalgacıkların karmaşıklık matrisleri

Elde edilen başarımlardan yola çıkarak, Haar dalgacığı gibi karesel dalgacıkların bu veri setinde yapılacak olan sınıflandırma çalışmalarında ortogonal dalgacıklardan daha az kullanışlı olduğu söylenebilmektedir. Benzer şekilde elde edilen başarımlardan yola çıkarak en iyi başarımın, kullanılan dalgacıklardan en az simetrik olan Symlet 4 dalgacığı kullanılarak DWT işlemi gerçekleştirilmesinin ardından elde edilen özneliliklerden kazanılması sebebiyle, en az simetrik olan dalgacıkların performansa olumlu katkısı olduğu ve daha iyi bir seçim olarak sayılabileceği söylenebilmektedir (Karakul ve Gökçen, 2023).

3.3. Ağaç Tohum Algoritması ile Makine Öğrenme Algoritmalarını Kullanarak Parmak Hareketi Tanıma

Bu çalışmada, Kaggle platformunda topluluğunda kullanımına açık şekilde paylaşılan ve bir önceki çalışmada da kullanılmış olan veri seti kullanılmıştır (İnternet, 2018a). Çalışmada, geleneksel makine öğrenmesi algoritmalarının sınıflandırma başarımlarını artırmak için Ağaç-Tohum Algoritmasının ve PSO optimizasyon algoritmaları kullanılmıştır. Çalışmada sEMG sinyalleri ile parmak hareketlerini sınıflandırmak için SVM, kNN, DT ve RF sınıflandırıcıları tercih edilmiştir.

Optimizasyon algoritmalarının bu çalışmadaki görevleri, çıkartılan öz nitelikler içerisinde en iyi performansı veren ve mümkün olan en az sayıda öz nitelik içeren alt öz nitelik grubunun seçilebilmesini sağlamaktır. Optimizasyon algoritmaları öz nitelikleri belirleyip test ederken makine öğrenmesi algoritmaları da seçilen alt öz nitelik grubunun sınıflandırma performansını bulmak için kullanılmıştır. Sınıflandırma aşamasından önce öz nitelik seçiminin yapılması, sınıflandırılacak veri boyutunu küçülteceğinden sınıflandırma hızını artırmaktadır. Çalışmanın amacı doğrultusunda, en az sayıda öz nitelik ile en yüksek başarımları veren öz nitelik alt grubu araştırıldığı için de hem sınıflandırma hızında hem de başarımlarında performans artımı gözlemlenmiştir.

TSA'nın keşfetme becerisi ve aramayı arama uzayındaki çoklu noktalarda yapmasının kazanımlarından faydalanmak ve farklı öz nitelik alt gruplarını test edebilmek için TSA kullanılmıştır. Çalışmanın amacı en küçük öz nitelik grubu ile en yüksek sınıflandırma başarımlarını elde etmek olduğu için, geliştirilen amaç fonksiyonunda hem seçilen öz nitelik sayısı hem de o öz niteliklerden elde edilen sınıflandırma başarımları kullanılmıştır.

Öz nitelik seçimi yapacak olan ağaç ve tohumlar için, ağaç ve tohumların her boyutu Karşılaştırma Parametresi (KP) isimli bir parametre ile kıyaslanmaktadır. Eş. 3. 1.'de gösterildiği üzere ağaç veya tohumların her boyutundaki değer KP ile kıyaslanır, eğer değer KP'den büyük ise 1, değil ise 0 olarak kabul edilir. 1 olarak kabul edilen boyutların indeksindeki öz nitelikler makine öğrenmesi yöntemlerinde kullanılmak üzere seçilir. Karşılaştırma parametresi çok küçük bir değer ile başlatılıp her iterasyonda artırılarak değeri büyütülmektedir. Bu sayede iterasyonların en başında en fazla öz nitelik seçilebiliyorken ilerleyen iterasyonlarda ağaç ve tohumlar daha az sayıda öz nitelik seçme eğilimine zorlanmış olmaktadır.

$$\text{öznitelik}_j = \begin{cases} 0, & V_{i,j} \leq KP \\ 1, & V_{i,j} > KP \end{cases} \quad (3.1)$$

Burada öznitelik_j jnci indekste bulunan özniteliği, KP karşılaştırma parametresini, V ise ağaç veya tohumu temsil etmektedir. jnci indekste bulunan özniteliğin inci ağaç veya tohumun jnci boyutundaki değerden büyük olması veya küçük olması durumuna göre seçilecek veya seçilmeyecektir.

Alt öznitelik grubunun belirlenmesinin ardından eğitim için ayrılan veri setinden alt grup öznitelikleri alınır ve makine öğrenmesi algoritmalarında kullanılır. Ardından eğitim veri seti ile beslenmiş olan makine öğrenmesi algoritmalarının test veri seti üzerindeki sınıflandırma başarımı alınır. Sınıflandırma başarımı ağaç veya tohumun uygunluk değeri olmaktadır. Hatalı sonuçlardan uzak durabilmek adına karşılaştırma parametresinin her iterasyonda artırılmış ve bu sayede aynı öznitelik alt gruplarının veya aynı sayıda özniteliğin tekrarlı şekilde seçilmesinin önüne geçilmiştir.

Her iterasyonda artan karşılaştırma parametresi değeri ile yeni ağaç ve ağaçlarla birlikte yeni tohumlar üretilmektedir. Yeni iterasyondaki artan karşılaştırma parametresi için, yalnızca karşılaştırma parametresinden büyük özniteliklerin seçilmesi durumu sebebiyle yeni oluşturulan ağaçların konumları daha az özniteliğin seçileceği konumlara yönlendirilmiş olmaktadır. Karşılaştırma parametresinin kontrollü ve düzenli şekilde artırılması, seçilen öznitelik sayısının sınıflandırmanın maksimum başarım vereceği kadar azaltılmasını sağlamaktadır. TSA'nın doğasından sebep, tohumlar konumlarını daha az veya daha çok öznitelik seçecekleri konumlara çekmeye çalışmaktadırlar. Eğer bir tohum daha düşük sayıda özniteliğin seçileceği bir konumda en yüksek başarıma ulaşırsa artık bu tohum en iyi konuma sahip olacağı için ağacın yerini alır ve diğer oluşturulacak tohumlar da bu tohuma yakın pozisyonlarda tekrar yerleştirilirler. Bu da tohumların konumlarının en az öznitelik sayısı ile en yüksek başarıma ulaşabilecekleri noktalara çekeceğinden, tohumlar daha az öznitelik seçilecek noktalara konumlanmış olurlar.


Bu çalışma, en yüksek sınıflandırma başarısının en düşük adet öznitelik ile seçilmesini hedeflemektedir. Yani, birbirlerinden bağımsız, gürültüye sebep olan, uç değer taşıyan, sınıflandırma başarımına olumlu etkisi olmayan veya olumsuz etkisi olan, diğerlerinden daha az etkili öznitelikleri kaldırarak yalnızca sınıflandırmada yüksek etkili özniteliklerin seçilmesi ve bu özniteliklerden bir alt grup oluşturularak en yüksek sınıflandırma başarımının elde edilmesi hedeflenmektedir. Sonuç olarak ağaçlar ve tohumlar en iyi

konumdaki ağaca yani en yüksek başarıyı en düşük sayıda öznitelik ile veren konumdaki ağaca yaklaştırmaya çalıştıkları, konumlarını o konuma çekmeye çalıştıkları için en yüksek performansı veren, sınıflandırmayı olumlu yönde en çok etkileyen öznitelikler daha sık seçilebilecek ve alt gruplarda daha sık birlikte yer alacaklardır. Bu sayede en az başarıyı veren öznitelik alt gruplarındaki özniteliklerden uzak durulup en yüksek başarıyı veren öznitelik alt gruplarındaki özniteliklerin seçilebileceği konumlarda tohum ve ağaçlar oluşturulmuş olacaktır.

3.3.2. Amaç fonksiyonu

Öznitelik seçim problemini, Ağaç-Tohum Algoritması ile çözmek için probleme uygun bir amaç fonksiyonunun oluşturulması gerekmektedir. Bu amaç doğrultusunda, geçmiş kaynaklarda kullanılmamış bir amaç fonksiyonu önerilmektedir. Eş. 3. 2.'de gösterilen basit geometrik eşitlikler kullanılarak tasarlanan amaç fonksiyonu, yüksek sınıflandırma başarımlarına az sayıda öznitelik ile erişimin sağlanması üzere tasarlanmıştır.

Öznitelik seçimi problemi öznitelik sayısı ve sınıflandırma başarımları olmak üzere iki boyutludur. İki boyutlu bir uzayda orijinden başlayarak belirli bir noktaya giden düz bir çizgi çizildiğini düşünelim. Bu uzayda, öznitelik sayısı X boyutunu, sınıflandırma başarımları ise Y boyutunu göstermek üzere, orijinden çizilen çizginin varış noktası X ve Y boyutlarının yani öznitelik sayısı ve sınıflandırma başarımlarının kesiştiği noktayı göstermektedir. Bir diğer deyişle, çizginin varış noktası seçilen öznitelik sayısı ile elde edilen başarıyı ifade etmektedir. Örnek bir durum Şekil 3.5.'de gösterilmektedir.



Şekil 3.5. Amaç fonksiyonunun üzerinde çalıştığı noktaların örnek gösterimi

Çizginin çizilmesi sonrası çizgi ile X boyutu arasında bir açı oluşur. Eğer bu açı yüksek ise eğrinin yüksek X değerine yani yüksek sayıda özniteliğe ve düşük Y değerine yani düşük sınıflandırma başarımına sahip olduğu anlaşılır. Fakat eğer iki boyutlu uzayda iki nokta oransal X ve Y değerlerine sahip ise çizgileri birbirlerinin üzerinden geçeceğinden çizgilerin açıları da aynı olacaktır. Bu problemten ötürü, eşitliğe çizilen çizginin uzunluğu da eklenmiştir. Bu sayede aynı eğime eğriler oluşturan iki noktanın obje fonksiyon değerleri farklı olacak ve en yüksek başarımı veren en düşük öznitelik sayısını gösteren nokta daha değerli kabul edilecektir.

$$f(a) = \tan^{-1} \frac{Y}{X} + \sqrt{X^2 + Y^2} \quad (3.2)$$

Burada, X seçilen öznitelik sayısını, Y ise sınıflandırma başarımını gösterirken $f(a)$ uygunluk değerini ifade etmektedir.

Aşağıdaki tabloda optimizasyon algoritmaları kullanılarak öznitelik seçimi ile başarımların artırma çalışmasının başlangıç ve bitiş sınıflandırma başarımları verilmiştir. Sınıflandırma başarımına ek olarak, en yüksek sınıflandırma başarımını veren öznitelik sayısı da verilmiştir. Çalışmanın asıl amacı, Ağaç-Tohum Algoritması kullanılarak en yüksek sınıflandırma başarımını en düşük öznitelik sayısı ile elde etmektir. Ağaç-Tohum Algoritmasının performansını kıyaslamak için PSO algoritması kullanılmıştır. Tabloda görüldüğü üzere, Ağaç-Tohum Algoritması sınıflandırıcıların başarımını PSO'nun eriştiğinden daha yüksek başarımlara çıkaracak şekilde daha az özniteliği seçebilmiştir. Sadece geleneksel makine öğrenmesi yöntemlerinin kullanıldığı çalışmada pencereleme yönteminde üst üste binmenin kullanılan veri setinde olumlu etkisi olduğu görülmüştü. Bu sebeple, bu çalışmada da benzer bir kıyas yapılarak optimizasyon algoritmalarına verilecek olan öznitelikler üst üste binme yöntemi kullanılarak ve kullanılmayarak çıkartılmış ve performansları kıyaslanmıştır. Üst üste binme yönteminin kullanıldığı veri setlerinde başlangıç sınıflandırma başarımı yüksek olduğundan başarımların değişimi çok fark edilmemektedir fakat daha düşük sınıflandırma başarımı ile başlayan deneylerde sınıflandırma başarımı daha belirgindir.

PSO, TSA'yı en az öznitelik bulma konusunda birkaç deneyde geçmiş olsa da çalışmanın amacı olan en yüksek başarımları en az öznitelik ile bulma konusunda TSA'nın gerisinde kalmıştır. PSO'nun en az özniteliği bulduğu deneylerde TSA daha yüksek başarımlara erişmiştir. Erişilen en yüksek sınıflandırma başarımı olan 99.75%, 12.5% daha az

öznitelikle, TSA ve kNN 'nin birlikte kullanıldığı durumda gözlemlenmiştir. En yüksek başarımın alındığı bu deneme, üst üste binen pencere yöntemi kullanılarak çıkartılan öznitelikler ile elde edilmiştir. Bu durumda, üst üste binen pencere yönteminin bu veri setinde yapılacak sınıflandırma çalışmalarında iyi bir seçenek olduğu görülmüştür.

Çizelge 3.3. PSO ve TSA kullanılarak elde edilen başarımlar

Üst üste binen Pencere Kullanıldı mı? (E/H)	Optimizasyon Algoritması	Makine öğrenmesi algoritması	Başlangıç sınıflandırma başarımı	Bitiş sınıflandırma başarımı	Öznitelik Sayısı
E	TSA	SVM	88.2	92.93	73
		kNN	99.67	99.75	70
		DT	99.1	99.53	71
		RF	99.53	99.64	74
	PSO	SVM	90.21	92.3	70
		kNN	99.59	99.72	78
		DT	99.01	99.20	72
		RF	99.31	99.48	77
H	TSA	SVM	93.43	93.5	77
		kNN	84.78	90.21	50
		DT	90.76	93.47	44
		RF	91.84	93.47	69
	PSO	SVM	92.4	92.46	75
		kNN	87.5	90.76	48
		DT	86.41	89.13	42
		RF	88.04	90.21	57

Üst üste binen pencereler kullanılmadan elde edilen öznitelikler kullanılarak yapılan deneyler, üst üste binen pencerelere kıyasla daha az detaya ve daha az örneğe sahip olması sebebiyle daha düşük sınıflandırma başarımları ile başlamaktadır. Fakat, daha düşük başarımlarla başlayan örnekler sınıflandırma başarımındaki değişimi daha net şekilde göstermektedir.

Bu çalışmada kullanılan veri seti kullanılarak yapılan literatürdeki geçmiş çalışmalar ve EMG verilerini optimizasyon algoritmaları ile kullanan çalışmalar aşağıdaki tabloda gösterilmektedir. İlk beş çalışma bu çalışmada kullanılan veri seti ile aynıdır. Bu çalışmaların arasında, Bittibbissi ve arkadaşlarının LSTM kullanarak yaptıkları çalışma bu veri setinde yapılan geçmiş çalışmalar arasında en yüksek başarımı 99.6% sınıflandırma başarımı ile vermektedir (Bittibbissi ve diğerleri, 2021). Bu çalışmada raporlanan en

yüksek sınıflandırma başarımı ise 99.75% dir. İlk beş çalışmanın dışındaki çalışmalar, çeşitli veri setleri, farklı makine öğrenmesi yöntemleri ve optimizasyon algoritmaları kullanılarak yapılan çalışmalardır. Farklı veri setleri arasında yapılan çalışmalar arasında en yüksek sınıflandırma başarımı Subasi'nin PSO ve SVM kullanarak yaptığı çalışmalarında 97.41% dir (Subasi, 2013). Bazı çalışmalar sınıflandırma başarımını artırmak için (Too ve diğerleri, 2018; Too ve diğerleri, 2019; Too ve diğerleri, 2019) çeşitli optimizasyon algoritmalarının performanslarını artırmak üzere çalışmışken, farklı çalışmalarda da öznitelik sayısını azaltmak üzere çalışmalar yapılmıştır (Huang ve diğerleri, 2012; Subasi, 2013; Naseer ve diğerleri, 2018; Jain ve diğerleri, 2021; Jain ve diğerleri, 2020). Literatürdeki çalışmalar incelendiğinde TSA'nın EMG sınıflandırma probleminde öznitelik azaltmak için ilk kez kullanıldığı görülmektedir. Bu çalışmada, TSA ve çeşitli geleneksel makine öğrenmesi yöntemleri kullanılarak EMG verilerinin sınıflandırılmasında sınıflandırma başarımının artırılması ve öznitelik sayısının azaltılması sağlanmıştır. TSA'nın performansı bir diğer optimizasyon algoritması olan PSO ile kıyaslanmış fakat TSA performansta PSO'yu gerisinde bırakmıştır. En yüksek sınıflandırma başarımı TSA ve kNN kullanılarak, 80 öznitelikten 70inin seçilmesi ile 99.75% olarak gözlemlenmiştir (Karakul ve Gökçen, 2024).

Çizelge 3.4. Literatürde bulunan çalışmalar ile kıyas tablosu

Çalışma	Kullanılan veri seti	Optimizasyon Algoritması	Sınıflandırma Algoritması	En yüksek başarımlar
Naseer ve diğerleri, 2017	Naseer ve diğerleri, 2017	GA	LDA, KNN, SVM, DNN	97.4 (KNN)
Jain ve diğerleri, 2021	Naseer ve diğerleri, 2017	GA	ANN	95
Jain ve diğerleri, 2020	Naseer ve diğerleri, 2017	GA	SVM ve KNN	92.4
Bittibssi ve diğerleri, 2021	Naseer ve diğerleri, 2017	-	LSTM	99.6
Farag ve diğerleri, 2021	Naseer ve diğerleri, 2017	-	CNN	90.8
Too ve diğerleri, 2018	NinaPro4	CBGWO	KNN	92.69
Huang ve diğerleri, 2012	Kendi veri setleri	Ant colony opt. (ACO)	BPNN	96.08
Too ve diğerleri, 2019	NinaPro4	BPSODE	KNN	92.5
Too ve diğerleri, 2019	NinaPro3	PBPSO	KNN	85.20

Çizelge 3.4. (Devam) Literatürde bulunan çalışmalar ile kıyas tablosu

Çalışma	Kullanılan veri seti	Optimizasyon Algoritması	Sınıflandırma Algoritması	En yüksek başarımlar
Subasi, 2013	Subasi ve diğerleri, 2006	PSO	RBFN, KNN, SVM	97.41 (PSO-SVM)
Sahu ve diğerleri, 2023	NinaPro3	GGABC	KNN	97.06
Bu çalışma	Naseer ve diğerleri, 2017	TSA	SVM, KNN, RF, DT	99.75 (TSA-KNN)

3.4. Cinsiyet Tespiti Çalışması

sEMG sinyalleri ile yalnızca yapılan hareket değil, aynı zamanda hareketi uygulayan kişinin cinsiyet gibi demografik özellikleri de tespit edilebilmektedir. İnsanların en önemli demografik özelliklerinden biri cinsiyettir (Antal ve Nemes, 2016). Öneri sistemleri gibi kişiler hakkında bilgi ihtiyacı duyan sistemlerin performanslarını artırmak için cinsiyet tespiti kullanılabilir (Ng, Tay ve Goi, 2015). Bireylerin cinsiyetlerinin ayırt edilmesi bilgi güvenliğinden insan-bilgisayar etkileşim sistemlerine kadar birçok alanda kullanışlıdır (Hu, 2018). Literatürde cinsiyet tespit, cinsiyet tanıma gibi problemlerin çözümleri üzerine birçok çalışma mevcuttur. Bu çalışmalarda çeşitli görseller ile tespit yapıldığı gibi EKG, EEG, EMG gibi sinyalleri ile de tespit probleminin çözülebileceği gösterilmiştir. Cao ve arkadaşları, insanların ön ve arka vücut görüntülerinden cinsiyet tespiti yaptıkları bir sistem oluşturmuşlardır. Araştırmacılar, ilk olarak insan vücut görüntülerinin özneteliklerini Rastgele Orman ve Ada Boost sınıflayıcılarına uygulayıp önerdikleri Parça-Tabanlı Cinsiyet Tanıma (Part-Based Gender Recognition, PBGR) algoritmasının sonuçları ile kıyaslamışlardır. Kıyaslama sonucunda önerdikleri algoritma, ön ve arka vücut görüntüleri için sırasıyla 76.0 ± 1.2 ve 74.6 ± 3.4 doğruluk oranlarıyla en iyi sonucu vermiştir (Cao, Dikmen, Fu ve Huang, 2008). Mansanet ve arkadaşları, cinsiyetleri başarıyla ayırmak amacıyla Yerel Derin Sinir Ağları (Local Deep Neural Networks, Local-DNN) modelini önermişlerdir. Pencereleştirilen yüz görüntülerinden elde edilen yerel özellikler ile eğittikleri derin öğrenme modelinde 96.25 doğruluk oranı elde etmişlerdir (Mansanet, Albiol ve Paredes, 2016). Görüntüleri kullanarak cinsiyet problem çözümüne odaklanan bir diğer çalışmada, Dhomne ve arkadaşları, ünlü kişilerin görüntülerini kullanmışlardır. Ünlü kişilerin görüntülerini kullanan araştırmacılar çalışmalarında VGGNet mimarisi ile 95.0 doğruluk oranı elde etmişlerdir (Dhomne, Kumar ve Bhan, 2018). İnsanların yüz görüntülerini barındıran farklı veri setlerinin kullanıldığı bir diğer çalışmada, araştırmacılar SVM ve CNN içeren hibrit bir makine

öğrenimi modeli önermiş ve 97.3 ± 0.5 doğruluk oranı elde etmişlerdir (van de Wolfshaar, Karaaba ve Wierring, 2015).

Alnuaim ve arkadaşları, ResNet mimarilerinin ses verileri üzerindeki cinsiyet tanıma başarımını incelemişlerdir. ResNet34 ve ResNet50 mimarilerini kullanan araştırmacılar verimlilik karşılaştırması yapmışlardır. Sırası ile ResNet34 ve ResNet50 mimarileri için 97.94 ve 98.57 doğruluk oranı elde etmişlerdir (Alnuaim, Zakariah, Shashidhar, Hatamleh, Tarazi, Shukla ve Ratna, 2022). Ses verisi ile cinsiyet tespiti üzerine olan bir diğer çalışma ise Büyükyılmaz ve Çıbıkdiken tarafından yapılmıştır. Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP) ve derin öğrenme modeli kullanarak cinsiyet sınıflandırma yapan araştırmacılar, 96.74 doğruluk oranı elde etmişlerdir (Büyükyılmaz ve Çıbıkdiken, 2016). Tsimperidis ve arkadaşları, tuş vuruş dinamiğini kullanarak cinsiyet tespiti yapmak amacı ile bir veri seti oluşturmuşlardır. Çalışmalarında SVM, Naive Bayes (NB), Rastgele Orman ve MLP gibi çeşitli makine öğrenimi algoritmalarını kullanan araştırmacılar sonuçları kıyaslamışlardır. En iyi sonucu Radyal Baz Fonksiyon Ağı (Radial Basis Function Network, RBFN) ile alan araştırmacılar doğruluk oranlarını 95.6 olarak raporlamışlardır (Tsimperidis, Arampatzis ve Karakos, 2018).

Cinsiyet tanıma problemini çözmek için kullanılan tek biyometrik veri ses verisi değildir. Cabra ve arkadaşları, EKG verileri üzerine kimlik doğrulama ve cinsiyet tespiti için farklı sınıflandırıcıların bulunduğu bir sistem oluşturmuşlardır. Cinsiyet tespit problemi için k-NN sınıflandırıcısını kullanarak 95.1 başarımlık elde etmişlerdir (Cabra, Mendez ve Trujillo, 2018). EKG sinyalleri ile cinsiyet tespiti üzerine yapılan bir diğer çalışmada araştırmacılar, EKG sinyallerinin hem ham halini hem de filtrelenmiş halini kullanmışlardır. Ham ve filtrelenmiş EKG verilerinden cinsiyet tespiti yapabilmek için Uzun Kısa Vadeli Bellek (Long Short Term Memory, LSTM) ve Çift Yönlü Uzun Kısa Vadeli Bellek (BiLSTM) kullanmışlardır. En iyi başarımlık filtrelenmiş EKG sinyallerinden alan araştırmacılar LSTM ve BiLSTM için sırasıyla 79.03 ve 74.19 doğruluk oranı elde etmişlerdir (Halim, Nugraha, Faisal, Herteno ve Budiman, 2023). Khan ve arkadaşları ise EKG veri setinin özneliliklerinin boyutunu azaltmak için Çekirnek Ana Bileşen Analizi (Kernel Principal Component Analysis, KPCA) kullanmış ve İyi Ağaç (Fine Tree) sınıflandırıcısı ile 95.2 doğruluk oranı elde etmişlerdir (Khan, Saad, Aziz, Ch, Naqvi ve Qasim, 2020).

Wang ve Hu, sessiz bir odaya oturttukları katılımcılardan EEG verileri toplamışlardır. Veri toplama işleminde, katılımcıların hiçbir şey yapmadan gözleri açık oturmaları istenmiştir. Katılımcıları 20 dakika boyunca oturtan araştırmacılar, 20 dakikanın yalnızca son 5 dakikasında EEG verilerini kaydetmişlerdir. EEG verilerinden cinsiyet tespiti yapmak için RF ve LR tabanlı hibrit bir model öneren araştırmacılar, %99.83 doğruluk oranına ulaşmışlardır (Wang ve Hu, 2019). Zhang ve arkadaşları, EEG verilerinden elde ettikleri faz-kilitli değer (Phase-locked value, PLV) ve zaman-frekans özniteliklerini kullanarak sınıflandırma yapmışlardır. Araştırmacılar, özellik sayısını azaltmak için Ana Bileşen Analizi (Principal Component Analysis, PCA) kullanmış ve elde ettikleri öznitelik kümeleri ile k-NN, SVM ve Aşırı Öğrenme Makinesi (Extreme Learning Machine, ELM) yöntemlerini kullanıp kıyaslamışlardır. Kıyaslarının sonucunda en yüksek başarıyı EEG verilerinde PLV özniteliklerinin ELM ile kullanımı neticesinde %81.73 doğruluk oranı ile elde etmişlerdir (Zhang, Xu, Zhu, Kong ve Ma, 2019).

Rosli ve arkadaşları, EMG ve Kalp Atış Hızı Değişkenliği (Heart Rate Variability, HRV) öznitelikleri ile cinsiyet tespit başarımını artırmak üzerine çalışmışlardır. EMG ve EKG özniteliklerini kullanan araştırmacılar, EMG ve EKG özniteliklerini Kombinatorial Füzyon Yöntemi (Combinatorial Fusion Approach, CFA) ile kıyaslamışlardır. Öznitelikleri birleştirip k-NN, NB, DT (j48) ve SVM yöntemlerini kullanarak başarıyı kıyası yapan araştırmacılar, en iyi ortalama doğru tespiti CFA ile elde etmişlerdir (Rosli, Abdul Rahman, Balakrishnan, Komeda, Mazlan ve Zamzuri, 2017). EMG tabanlı bir diğer çalışmada ise yüz EMG verileri üzerinden cinsiyet tespiti yapılmıştır. Araştırmacılar Davies-Bouldin indeksini kullanarak kümeleme ve cinsiyet tespiti, sınıflandırması, yaparak %80 doğruluk oranı elde etmişlerdir (Godiyal, Sharma, Joshi ve Bhatia, 2013).

Lee ve arkadaşları, yürüme özniteliklerinin analizi ile cinsiyet tespiti için yeni bir yaklaşım önermişlerdir. Araştırmacılar, iki farklı Özyinelemeli Öznitelik Eleme (Recursive Feature Elimination, RFE) yöntemi ile en iyi özellik alt kümelerini belirlemişlerdir. Kullandıkları RFE yöntemleri Rastgele Orman Tabanlı Özyinelemeli Öznitelik Eleme (Random Forest-based Recursive Feature Elimination, RF-RFE) ve Destek Vektör Makinesi Tabanlı Özyinelemeli Öznitelik Eleme (Support Vector Machine-based Recursive Feature Elimination, SVM-RFE) yöntemleridir. Öznitelik alt kümelerini RF ve SVM ile sınıflandıran araştırmacılar, %99.11 doğruluk oranı ile cinsiyet sınıflandırması yapabilmışlerdir (Lee, Lee ve Kim, 2022).

Tezin bu bölümünde oluşturulan özgün bir veri seti kullanılmıştır. Oluşturulan özgün veri setinde, homojen cinsiyet dağılımına sahip 20 katılımcıdan 12 cümleyi 10 tekrar olacak şekilde yazmaları istenmiştir. Katılımcıların sEMG verileri MyoArmband isimli cihaz ile kaydedilmiştir. Tezin bu aşamasında amaç, yazı yazan katılımcıların ön kol sEMG verilerinden cinsiyet tespiti yapabilmektir.

3.4.1. Öznitelik çıkarımı

Birden fazla zaman serisi verisi, tek bir zaman serisi verisinden kayar pencere yöntemiyle elde edilebilir (Yu ve diğerleri, 2014). Bu çalışmada, sEMG verileri üzerinde kayar pencere yöntemi kullanılarak segmente edilmiş sinyallerin öznitelikleri çıkartılmıştır. Cinsiyet tanıma problemi için optimum pencere aralığı ve pencere kayma boyutu kombinasyonunu bulmak amacıyla çeşitli pencere aralıkları ve pencere kayma boyutları test edilmiştir. Pencere boyutları, sırasıyla 250 ms, 500 ms ve 1000 ms uzunluklarında seçilirken, kayma boyutu ise 25 ms, 50 ms ve 100 ms olarak belirlenmiştir.


Cümleler yazılırken kaydedilen sEMG verileri, 1500ms ile 4000ms aralığındadır. 50ms kaydırılma ile kullanılan 500ms pencere aralığındaki pencereler sayesinde ayrıntılı öznitelik çıkartılabilmektedir. Veriler 8 kanallı MyoArmband isimli cihazdan toplandığından, öznitelik çıkartımı da her kanaldan ayrı ayrı yapılmıştır. Çıkartılan öznitelikler RMS, SSC, WL, MAE, AAC, MFL, AP, ZC, VAR, STD olmak üzere 10 adettir. Öznitelik çıkarımı ardından her örneğin boyutu 1x80 haline gelmektedir.

3.4.2. CNN Mimarileri

Bu çalışmada, özgün veri seti ile ön kol sEMG verileri üzerinden cinsiyet tespiti yapılmıştır. Cinsiyet tespit çalışmasında, sEMG verilerinden çıkartılacak öznitelikler için optimum pencere aralığı ve pencere kayma boyutu araştırılması için çeşitli pencere aralıklarının çeşitli pencere kayma boyutları ile kombinasyonları uygulanmıştır. Elde edilen öznitelikler sınıflandırma sonucuna göre kıyaslanmıştır. Sınıflandırma işlemi için literatürde ön eğitilmiş kullanılan VGG16 ve AlexNet CNN mimarilerinin 1D versiyonları kullanılmıştır. Mimariler, kendi mimarimizin sonuçları ile karşılaştırılmıştır. Bildiğimiz kadarıyla daha önce ön kol sEMG verileri üzerinde kullanılmamış bir CNN mimarisi önerilmiştir.


Önerilen CNN mimarisi

Önerilen CNN mimarisinin oluşturulma sürecinde çeşitli evrişim blokları test edilmiştir. Yapılan denemelerin sonuçlarına göre her evrişim katmanının ardından maksimum havuzlama katmanının kullanılması veri kaybına neden olması sebebiyle cinsiyet tespit sınıflandırmasında başarıyı artırmadığı aksine düşürebildiği gözlemlenmiştir. Bu nedenle önerilen mimariye yalnızca bir adet maksimum havuzlama katmanı eklenmiştir. Evrişim katmanlarının filtre boyutları 32 ile başlayıp her katman için iki katına çıkartılarak tam bağlı katmana kadar artırılmıştır. Önerilen CNN modeli Şekil 3.6.'da gösterilmektedir.




Şekil 3.6. Önerilen CNN modeli

Önerilen CNN modelinin sonuçlarını, popüler önceden eğitilmiş CNN mimarileri ile karşılaştırmak amacıyla, AlexNet ve VGG16 mimarileri 1D versiyonlarıyla seçilmiştir. AlexNet ve VGG16 mimarilerinin yapıları sırasıyla Şekil 3.7. ve Şekil 3.8'de gösterilmektedir.



Şekil 3.7. VGG16 modelinin 1D mimarisi



Şekil 3.8. AlexNET modelinin 1D mimarisi

Bütün analizlerde, eğitim verileri için %75, test verileri için ise %25 ayrılmıştır. Dağılımlarda deneklere göre homojen bir dağılım yapılmıştır. Çeşitli hiper-parametrelerin kombinasyonları yapılan deneylerde test edilmiş ve en iyi sonucu veren optimum hiper-parametreler tüm mimarilerde uygulanmıştır. Yapılan analizlerde gözlemlenen en iyi sonuçları veren hiper-parametreler Çizelge 3.5.'te gösterilmektedir.

Çizelge 3.5. Modeller için hiper-parametreler

Her evrişim katmanı için aktivasyon fonksiyonu	ReLU
Seyreltme	50%
Optimizasyon	Adam
Öğrenme Oranı	0.001
Yığın Boyutu	256
Aktivasyon Fonksiyonu	Sigmoid

Farklı özellik setlerinin kullanılma nedeni, çeşitli pencere boyutu ve kayma boyutu kombinasyonları için sınıflandırma performanslarını karşılaştırmaktır. Seçilen her pencere kullanılarak oluşturulan özniteliklerin CNN mimarilerinde verdiği başarımlar, Çizelge 3.6.'da verilmiştir. Sonuçlar, doğruluk, hassasiyet, F1 skoru, hatırlama (recall) ve AUC skoru gibi farklı istatistiksel metrikler açısından karşılaştırılmıştır. Önerilen CNN modeli, tüm metrikler göz önünde bulundurulduğunda, VGG16 ve AlexNET mimarilerini geride bırakmıştır. sEMG verileri ile cinsiyet tespit problemine dair en iyi performans, tüm mimariler için 25ms kayma boyutunda elde edilmiştir. Buna göre, pencerelerin 25ms kayma boyutu ile hareket etmelerinin özniteliklerinin CNN modellerinin kişilerin yazma alışkanlıklarına göre cinsiyetlerini tespit etmeleri için daha ayrıntılı olduğu söylenebilir. Yapılan tüm deneylere kıyasla, en yüksek üç başarımlar bu kısımda, 25ms kayar pencere kullanılarak elde edilmiştir. İlk üç doğruluk oranı, sırasıyla önerilen CNN modeli, VGG16 ve AlexNET için %99.99, %99.97 ve %99.59'dur. Sonuçlara bakarak pencere boyutunun

da pencere kayma boyutu kadar önemli olduğunu, kişilerin yazma alışkanlıklarından cinsiyet tespit edilmesi için ön kol sEMG verilerinin önemli bir katkısı olduğu görülmektedir. Önerilen CNN mimarisi, 1000ms pencere uzunluğu için tüm kayma boyutlarında test edilen diğer 1D CNN mimarilerini geride bırakmıştır.

Çizelge 3.6. Modellerin çeşitli pencere ve kayma boyutları ile başarımları

Pencere Aralığı	CNN Mimarisi	Kayma Boyutu	Doğruluk	Hassasiyet	F1 Skoru	Duyarlılık	AUC Skoru
250ms	VGG16	25	99.55	99.56	99.57	99.69	99.54
		50	97.59	97.58	97.66	96.95	97.62
		100	96.81	96.79	96.91	96.53	98.82
	AlexNET	25	98.13	98.13	98.20	98.21	98.13
		50	96.79	96.78	96.89	96.28	96.81
		100	97.10	97.09	97.20	97.11	97.10
	Önerilen CNN Modeli	25	99.51	99.51	99.53	99.58	99.51
		50	98.68	98.68	98.72	98.78	98.67
		100	97.24	97.72	97.31	96.30	97.28
500ms	VGG16	25	99.65	99.65	99.67	99.64	99.65
		50	96.46	96.58	96.63	98.41	96.40
		100	98.02	98.05	98.14	98.73	97.97
	AlexNET	25	99.72	99.72	99.73	99.74	99.72
		50	98.83	98.83	98.87	98.96	98.83
		100	97.45	97.44	97.59	97.61	97.44
	Önerilen CNN Modeli	25	99.74	99.75	99.75	99.95	99.73
		50	99.59	99.59	99.60	99.60	99.59
		100	98.89	98.89	98.95	98.93	98.89
1000ms	VGG16	25	99.97	99.97	99.97	99.97	99.97
		50	99.52	99.51	99.55	99.49	99.52
		100	99.52	99.51	99.55	99.49	99.52
	AlexNET	25	99.59	99.58	99.62	99.45	99.60
		50	97.60	97.54	97.75	96.96	97.67
		100	97.46	97.47	97.61	97.86	97.44
	Önerilen CNN Modeli	25	99.99	99.99	99.99	100.0	99.98
		50	99.91	99.92	99.92	99.94	99.91
		100	99.33	99.34	99.37	99.45	99.32

Ek olarak, özneliklere normalizasyon uygulanarak da deneyler yapılmıştır. Öznelikler sütun bazında 0-255 aralığında değerlere sahip olacak şekilde normalize edilerek CNN mimarilerinde kullanılmışlardır. Çizelge 3.7.'de 250ms, 500ms ve 1000ms pencere aralıklarının kayan pencere boyutları ile kombinasyonları sonucu elde edilen özneliklerin CNN mimarilerinde kullanılması sonucu elde edilen sonuçlar gösterilmektedir.

Çizelge 3.7. Modellerin, normalize edilmiş çeşitli pencere ve kayma boyutları ile başarımları



Pencere Aralığı	CNN Mimarisi	Kayma Boyutu	Doğruluk	Hassasiyet	F1 Skoru	Duyarlılık	AUC Skoru
250ms	VGG16	25	99.45	99.45	99.47	99.38	99.45
		50	97.63	97.62	97.69	96.51	97.57
		100	97.24	97.24	97.35	97.61	97.22
	AlexNET	25	98.20	98.23	98.28	98.88	98.17
		50	98.68	98.68	98.72	98.93	98.67
		100	97.17	97.16	97.26	96.72	97.19
	Önerilen CNN Modeli	25	99.59	99.59	99.61	99.73	99.58
		50	98.90	98.90	98.94	98.74	98.91
		100	97.63	97.64	97.72	98.02	97.61
500ms	VGG16	25	99.72	99.72	99.73	99.83	99.72
		50	99.38	99.39	99.40	99.82	99.36
		100	98.42	98.39	98.49	98.08	98.44
	AlexNET	25	99.80	99.80	99.80	99.89	99.79
		50	99.47	99.47	99.49	99.57	99.47
		100	98.74	98.72	98.80	98.51	98.75
	Önerilen CNN Modeli	25	99.91	99.91	99.92	99.94	99.91
		50	99.81	99.81	99.82	99.84	99.81
		100	99.12	99.12	99.17	99.14	99.12
1000ms	VGG16	25	99.98	99.97	99.98	99.97	99.98
		50	99.86	99.87	99.87	99.90	99.86
		100	99.52	99.52	99.55	99.53	99.52
	AlexNET	25	99.20	99.25	99.26	99.92	99.15
		50	99.69	99.69	99.71	99.73	99.69
		100	99.13	99.11	99.18	99.02	99.13
	Önerilen CNN Modeli	25	99.98	99.98	99.98	99.99	99.97
		50	99.95	99.96	99.96	99.98	99.95
		100	99.81	99.81	99.82	99.92	99.80

Çizelge 3.8.'de, mimarilerin her birinin en iyi performans veren versiyonlarının karşılaştırması sunulmuştur. VGG16 mimarisi ve önerilen mimari, en iyi başarımlarını açıkça 1000ms pencere aralığı ve 25ms kayan pencere boyutu kullanılarak çıkartılan özniteliklerden elde etmişlerdir. AlexNet mimarisi ise, en iyi başarımını 500ms pencere aralığı ve 25ms kayan pencere kullanılarak çıkartılan özniteliklerden elde etmiştir. Kıyaslanan kayan pencere boyutlarından en iyi performansı veren 25ms olmuştur. Tüm en iyi başarımlar 25ms kayan pencere kullanıldığında gözlemlenmiştir. Normalizasyon işleminin ardından sınıflandırma başarımının arttığı net bir şekilde söylenemese de çeşitli metriklerde yükselme görülmüş olup sonuçlar birbirlerine yakın hale gelmiştir. Bu sebeple normalizasyon uygulanan özniteliklerle çalışan CNN mimarilerinin daha istikrarlı olduğu söylenebilir.

Çizelge 3.8. En iyi başarıımı veren modellerin metrikleri

CNN Modeli	Öznitelikler Normalize Edildi mi? (E/H)	Pencere Aralığı	Kayma Boyutu	Doğruluk	Hassasiyet	F1 Skoru	Duyarlılık	AUC Skoru
VGG16	E	1000	25	99.98	99.97	99.98	99.97	99.98
AlexNET	E	500	25	99.80	99.80	99.80	99.89	99.79
Önerilen Mimari	H	1000	25	99.99	99.99	99.99	1.0	99.98

Çalışmanın amacı, katılımcılardan yazı yazarlarken toplanan ön kol sEMG verilerinden cinsiyet tespiti yapmaktır. Çalışma sonuçları göstermektedir ki, yazma alışkanlıkları cinsiyetler arasında farklılık göstermektedir. Çalışmada 1D CNN mimarisi önerilmiş, performansı popüler 1D mimariler ile karşılaştırılmıştır. Her mimari çeşitli pencere aralıkları ve pencere kayma boyut kombinasyonlarından elde edilen öznitelikler ile karşılaştırılmıştır. Öznitelikler ile mimarilerin performansları, özniteliklere normalizasyon uygulanmadan önce ve sonra tekrar kıyaslanmış ve en iyi performansı veren versiyonları da Çizelge 3.8.'de verilmiştir. Normalize kullanarak ve kullanmayarak her pencere aralığı için elde edilen en iyi başarımlar Şekil 3.9.'da gösterilmektedir.




Şekil 3.9. (a) Normalize edilmeyen


Şekil 3.9. (a) Normalize edilen

Şekil 3.9. Normalize edilmeyen ve normalize edilen öznitelikler ile farklı pencerelerden elde edilen başarımlar

Yapılan tüm analizlerin sonucunda en iyi performansı veren cinsiyet tespit mimarisi 1000ms pencere aralığı ve 25ms pencere kayma boyutu kullanan önerilen CNN mimarisi olmuştur. Normalize kullanarak ve kullanmayarak kullanılan öznitelikler için önerilen CNN mimarisinin doğruluk grafikleri Şekil 3.10'da gösterilmektedir.



Şekil 3.10. (a) Normalize edilmeyen



Şekil 3.10. (a) Normalize edilen

Şekil 3.10. Normalize edilmeyen ve normalize edilen öznelilikler için önerilen CNN mimarisinin en iyi başarımlarını verdiği pencere boyutlarının doğruluk grafikleri

Literatürdeki çalışmalara dayalı karşılaştırma Çizelge 3.9.'da gösterilmektedir. Farklı sinyal türlerinin yanı sıra, çoğu çalışma görüntü kullanarak cinsiyet sınıflandırmaya odaklanmıştır (Cao ve diğerleri, 2008; Manaset ve diğerleri 2016; Dhomne ve diğerleri, 2018; van de Wolfshaar ve diğerleri, 2015). Ancak, görsellerin analiz edilmesi, 2D CNN modelleri kullanarak yapılan hesaplamalar nedeniyle yapay zeka modelinin karmaşıklığını arttırmaktadır. Bu karmaşıklık değerleri, yalnızca girişe bağlı olmayıp, önceden eğitilmiş CNN yapısına göre değişkenlik göstermektedir. Bu çalışmalarda, araştırmacılar çoğunlukla 2D-CNN mimarilerini kullanmış ve ana cinsiyet tanıma sorununu çözmek için farklı yöntemlerle hibrit CNN'ler önermişlerdir.

Wolfshaar ve ark. SVM'yi, CNN'nin özellik öğrenme aşamasıyla birleştirerek iki farklı veri seti için cinsiyet tanıma performansını geliştirmiştir (van de Wolfshaar ve diğerleri, 2015). Literatürdeki çalışmalarda, biyometrik veri setlerinin sıklıkla kullanıldığı görülmektedir (Alnuaim ve diğerleri, 2022; Büyükyılmaz ve Çıbıkdiken, 2016; Cabra ve diğerleri, 2018; Khan ve diğerleri, 2020; Rosli ve diğerleri, 2017; Godiyal ve diğerleri, 2013; Lee ve diğerleri, 2022). Sesli asistanlar gibi sistemlerde cinsiyet bilgisi önemli olduğu için, birçok çalışma ses veri setlerine odaklanmıştır (Alnuaim ve diğerleri, 2022; Büyükyılmaz ve Çıbıkdiken, 2016). Alnuaim ve arkadaşları, önceden eğitilmiş ResNet34 ve ResNet50 modellerinin ses spektrogramları üzerindeki performansını inceleyerek %98.57 doğruluk oranı elde etmişlerdir.

Başka bir biyometrik veri olan EKG sinyali de cinsiyet tanıma problemi için tercih edilmiştir. Bu çalışmaya benzer şekilde, (Cabra ve diğerleri, 2018; Khan ve diğerleri, 2020; Rosli ve diğerleri, 2017) 'da araştırmacılar, EKG sinyallerinden elde edilen el yapımı öznitelikleri kullanarak cinsiyet sınıflandırma problemi çözmeye odaklanmışlardır. Cabra ve arkadaşları, EKG sinyalleri ile kimlik doğrulaması ve cinsiyet tespiti için karar ağacı, SVM, kNN ve ANN sınıflandırıcılarını kullanmışlardır. İki farklı EKG veri seti kullanan araştırmacılar kimlik doğrulama ve cinsiyet tespiti açısından elde ettikleri sınıflandırma sonuçlarına göre değerlendirmişlerdir.

Geçmiş çalışmalarda sEMG sinyalleri de cinsiyet tespiti problemini çözmek için kullanılmıştır (Rosli ve diğerleri, 2017; Godiyal ve diğerleri, 2013; Lee ve diğerleri, 2022). Bu çalışmalar, farklı vücut bölgelerinden alınan sinyallere odaklanmış ve cinsiyetleri sınıflandırmak için ek öznitelikler kullanmışlardır. Rosli ve arkadaşları, HRV ve EMG sinyallerini kombinatorial füzyon yöntemi ile kullanmıştır. Araştırmacılar, özellik seçimine odaklanmış ve EMG ile HRV özelliklerinin en iyi kombinasyonunu bulmayı amaçlamışlardır. Bunu başarmak için, adım atma sırasında EMG ve HRV verilerinden öznitelikler çıkarmışlardır. İlk olarak, öznitelikleri NB, kNN ve karar ağacı (j48) gibi farklı sınıflandırıcılarla sınıflandırmışlardır. En iyi performansı veren sınıflandırıcı, özniteliklerin tekli performanslarını görmek için kullanılmıştır. En iyi performans gösteren öznitelikler birleştirilmiş ve skor kombinasyonu hesaplamak için kullanılmıştır. CFA, kNN, SVM ve DT (J48) arasında en iyi ortalama skor kombinasyonunu elde etmişlerdir. Tez çalışmasında önerilen fikrin ana farkı, ham sEMG'den çıkarılan tüm öznitelikleri kullanarak cinsiyet tanıma performansını daha derin bir analizle en yüksek seviyeye çıkarmaktır. Ayrıca, sEMG sinyalinin cinsiyet tanıma üzerindeki kapasitesini keşfetmek amacıyla farklı boyutlarda pencereler ve kayan pencere boyutları kullanarak çeşitli kombinasyonlar test edildi. Onların çalışması, EMG sinyallerini diğer biyometrik verilerle farklı yöntemler kullanarak birleştirmeyi baz alıyor, oysa bu çalışma yalnızca ham sEMG sinyallerinden çıkarılan öznitelikleri kullanarak mümkün olan en yüksek sınıflandırma oranını elde etmeye odaklanmıştır.

Lee ve arkadaşları, yürüme özniteliklerini kullanarak cinsiyet tespiti yapmayı amaçlamışlardır. Araştırmacılar, katılımcıların yürüdükleri esnada bacaklarından sEMG verilerini toplamışlardır. Öznitelikleri hem zaman alanından hem de frekans alanından çıkartan araştırmacılar, iteratif öznitelik eleme ile ve eleme olmadan RF ve SVM sınıflandırıcılarıyla yapılan deneylerin sonuçlarını raporlamışlardır. Öznitelik boyutunu

azaltarak en iyi öznitelik alt kümesini elde etmek için RF-RFE ve SVM-RFE kullanmışlardır. SVM-RFE kullanarak %99.11 doğruluk oranı elde etmişlerdir. Bu çalışmada ise istatistiksel ve entropi özniteliklerinin birleştirilmesi ve çeşitli CNN mimarilerinde farklı pencere kayma boyutlarıyla farklı pencereler aralıklarının performans sonuçlarına etkisinin gözlemlemesi ve en iyi kombinasyonun bulunması amaçlanmıştır.

Godiyal ve arkadaşları, cinsiyet sınıflandırma problemini çözmek için yüz EMG sinyalleri kullanmışlardır. Yüz EMG sinyallerinden öznitelikler çıkaran araştırmacılar Davies-Boulding indeksi kullanarak cinsiyet sınıflandırma yapmışlardır. Godiyal ve ark. üç zaman alanı özelliği kullanırken, bu çalışmada kaslardaki elektriksel aktivitenin mimariler tarafından daha iyi öğrenmesi amacıyla on zaman alanı özneliği çıkartılmıştır. Godiyal ve ark. cinsiyet sınıflandırmasına odaklanmış ve deneklerin konuştukları süreçte yüzlerinden toplanan sEMG sinyallerini içeren bir veri seti üzerinde deneyler yapmışlardır. Bu çalışmada ise kişilerin yazma alışkanlıklarının cinsiyetlere göre farklılık gösterdiği CNN mimari ile sınıflandırma yaparak gösterilmesi amaçlanmıştır.

Literatürde birçok çalışma, farklı veri setleri kullanarak cinsiyet sınıflandırma problemi üzerine odaklanmış olsa da bildiğimiz kadarıyla, ön kol sEMG sinyalleri kullanılarak cinsiyet sınıflandırma problemi üzerinde 1D CNN ile yapılan herhangi bir çalışma bulunmamaktadır. Bu çalışmada, katılımcıların belirli cümleleri yazarken ön kollarından toplanan sEMG sinyalleri kullanılmıştır. Öznitelikler, farklı pencere aralıkları ve farklı kayan pencere boyutları kullanılarak çıkarılmıştır. Bu öznitelikler, normalizasyon uygulanmadan ve normalizasyon uygulanmış şekilde, farklı mimarilere sahip 1D CNN modellerine verilmiştir. Çalışma, yazma alışkanlıklarının cinsiyetlere göre farklılık gösterdiğini de kanıtlamaktadır. Dahası, bu çalışma, cinsiyet tanıma problemi üzerine yapılan önceki tüm çalışmalardan daha iyi sonuçlar elde etmiştir. Kıyaslamalar Çizelge 3.9.'da gösterilmektedir.

Çizelge 3.9. Literatürde bulunan çalışmalar ile kıyaslama tablosu

Çalışma	Veri Seti	Yöntem	Doğruluk (%)
Alnuaim ve diğerleri, 2022	Ses veri seti	ResNet34 ve ResNet50	97.94 ve 98.57
Büyükyılmaz ve Çıbıkdiken, 2016	Ses veri seti	MLP	96.74
Cabra ve diğerleri, 2018	ECG veri seti	k-NN	95.10
Halim ve diğerleri, 2023	ECG	LSTM ve BiLSTM	79.03 ve 74.19

Çizelge 3.9. (Devam) Literatürde bulunan çalışmalar ile kıyaslama tablosu

Çalışma	Veri Seti	Yöntem	Doğruluk (%)
Khan ve diğerleri, 2020	ECG	KPCA + Fine tree sınıflandırıcısı	95.20
Wang ve Hu, 2019	EEG	RF+LR	99.83
Zhang ve diğerleri, 2019	EEG	PCA + ELM	81.73
Rosli ve diğerleri, 2017	EMG ve ECG	CFA	94.51
Godiyal ve diğerleri, 2013	Yüz EMG	Davies-Bouldin İndeksi	80.00
Lee ve diğerleri, 2022	EMG yürüyüş özellikleri	SVM-RFE + RF	99.11
Bu Çalışma	EMG	Önerilen Model	99.99
Bu Çalışma	EMG	1D AlexNet	99.80
Bu Çalışma	EMG	1D VGG16	99.98

En iyi başarımlar, önerilen CNN modelinin verdiği %99.99 doğruluk oranı ile elde edilmiştir. İkinci en iyi başarımlar ise VGG16 mimarisinin verdiği %99.98 doğruluk oranıdır. Her iki başarımlar da, 1000ms pencere aralığı ve 25ms kayan pencere boyutu kullanılarak çıkartılan özneliliklerden elde edilmiştir. VGG16 mimarisi normalize edilen veriler ile bu başarımları kazanırken, önerilen CNN modeli normalize edilmemiş veriler ile en yüksek başarıma ulaşmıştır.

4. SONUÇLAR

Bu tezde iki farklı sEMG veri seti kullanılarak çeşitli sınıflandırmalar yapılmıştır. Sınıflandırmalar için geleneksel makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. Tezin ilk üç aşamasında Kaggle platformunda topluluğun kullanımına açık şekilde paylaşılmış olan bir veri seti kullanılmıştır. Veri seti temel parmak hareketlerini ve zafer işaretini gerçekleştiren kullanıcıların sEMG verilerini barındırmaktadır. Yapılan çalışmalarda geleneksel makine öğrenmesi yöntemleri kullanılmıştır, bunlar RF, KNN, SVM ve DT algoritmalarıdır. Sınıflandırma başarımını artırmak için zaman alanı ve frekans alanı öznitelikleri kullanılmıştır. Frekans alanı özniteliklerini elde edebilmek adına DWT yöntemi üç farklı dalgacık ile uygulanmıştır. İlk aşamada elde edilen sınıflandırma başarımını arttırmak için, optimizasyon algoritmaları kullanılarak öznitelik seçimi yapılmıştır. Öznitelik seçimi yapılarak makine öğrenmesi algoritmalarında en yüksek başarıyı en az sayıda öznitelik ile elde etmek ve bu sayede daha az karmaşık bir öznitelik kümesinden yüksek başarıyı elde edilmesi hedeflenmiştir. Bu amaç doğrultusunda PSO ve TSA algoritmaları kullanılmıştır. Optimizasyon algoritmaları, öznitelikler içerisinde en yüksek başarıyı veren alt grubu seçip, düşük başarıyı veren ya da başarıyı düşüren özniteliklerin ise kullanımı engellemektedir. Yapılan çalışma sonucunda en yüksek başarıyı veren %99.75 doğruluk ile yapılan sınıflandırmada TSA algoritması ile %12 daha öznitelik seçilmiştir. TSA algoritması ile sEMG öznitelik seçimi, bildiğimiz kadarı ile, bu çalışma ile ilk kez yapılmıştır. Elde edilen başarıyı veri seti ile literatürde yapılan çalışmaların sınıflandırma başarımını da geçmektedir.

Çalışmanın sonraki aşamasında özgün sEMG veri seti oluşturulmuştur. Oluşturulan sEMG veri seti, kullanıcıların 12 cümleyi yazdıkları süreçte ön kol bölgelerinden toplanmıştır. Oluşturulan veri seti ile kullanıcıların cinsiyetlerinin tespit edilmesi ve kullanıcıların yazma alışkanlıklarına göre sEMG verilerinden cinsiyetlerinin tespit edilebildiği görülmüştür. Sınıflandırma işleminin gözlemlenmesi için üç farklı pencere boyutu ve üç farklı pencere kayma boyutu seçilmiştir. Sınıflandırma için tasarlanan CNN mimarisinin başarıyı, literatürde sıklıkla kullanılan VGG16 ve AlexNET modellerinin 1D mimarileri ile kıyaslanmıştır. Elde edilen sonuçlarda %99.99 doğruluk oranı ile tasarlanan CNN mimarisi, 25ms kayan 1000ms boyutlu pencereden elde edilen öznitelikler ile en yüksek başarıyı vermiştir.

5. KAYNAKLAR

Hu, Y., Wong, Y., Wei, W., Du, Y., Kankanhalli, M., ve Geng, W. (2018). A Novel Attention-Based Hybrid CNN-RNN Architecture For sEMG-based Gesture Recognition. *PloS one*, 13(10), e0206049.

Jaramillo-Yáñez, A., Benalcázar, M. E., ve Mena-Maldonado, E. (2020). Real-Time Hand Gesture Recognition Using Surface Electromyography And Machine Learning: A Systematic Literature Review. *Sensors*, 20(9), 2467.

Kim, J., Mastnik, S., ve André, E. (2008, January). EMG-Based Hand Gesture Recognition For Realtime Biosignal Interfacing. In *Proceedings Of The 13th International Conference On Intelligent User Interfaces* (pp. 30-39).

Zhou, T., Omisore, O. M., Du, W., Wang, L., ve Zhang, Y. (2019, October). Adapting Random Forest Classifier Based On Single And Multiple Features For Surface Electromyography Signal Recognition. In *2019 12th International Congress On Image And Signal Processing, Biomedical Engineering And Informatics (CISP-BMEI)* (pp. 1-6). IEEE.

Wahid, M. F., Tafreshi, R., ve Langari, R. (2019). A Multi-Window Majority Voting Strategy To Improve Hand Gesture Recognition Accuracies Using Electromyography Signal. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(2), 427-436.

Geng, W., Du, Y., Jin, W., Wei, W., Hu, Y., ve Li, J. (2016). Gesture Recognition By Instantaneous Surface EMG Images. *Scientific reports*, 6(1), 36571.

Tepe, C., & Erdim, M. (2022). Classification Of Surface Electromyography And Gyroscopic Signals Of Finger Gestures Acquired By Myo Armband Using Machine Learning Methods. *Biomedical Signal Processing and Control*, 75, 103588.

Wahid, M. F., Tafreshi, R., Al-Sowaidi, M., ve Langari, R. (2018, March). An Efficient Approach To Recognize Hand Gestures Using Machine-Learning Algorithms. In *2018 IEEE 4th Middle East Conference on Biomedical Engineering (MECBME)* (pp. 171-176). IEEE.

Zhang, Y., Chen, Y., Yu, H., Yang, X., Lu, W., ve Liu, H. (2018). Wearing-independent Hand Gesture Recognition Method Based on EMG Armband. *Personal and Ubiquitous Computing*, 22, 511-524.

Too, J., Abdullah, A. R., Zawawi, T. T., Saad, N. M., ve Musa, H. (2017). Classification of EMG Signal Based On Time Domain And Frequency Domain Features. *International Journal of Human and Technology Interaction (IJHaTI)*, 1(1), 25-30.

Altın, C., ve Er, O. (2016). Comparison Of Different Time And Frequency Domain Feature Extraction Methods On Elbow Gesture's EMG. *European journal of interdisciplinary studies*, 2(3), 25-34.

Duque, C. J. G., Muñoz, L. D., Mejía, J. G., ve Trejos, E. D. (2014, September). Discrete Wavelet Transform And K-Nn Classification in EMG Signals For Diagnosis Of Neuromuscular Disorders. In *2014 XIX Symposium on Image, Signal Processing and Artificial Vision* (pp. 1-5). IEEE.

Huang, H., Xie, H. B., Guo, J. Y., ve Chen, H. J. (2012). Ant Colony Optimization-Based Feature Selection Method For Surface Electromyography Signals Classification. *Computers in biology and medicine*, 42(1), 30-38.

Too, J., Abdullah, A. R., Mohd Saad, N., Mohd Ali, N., ve Tee, W. (2018). A New Competitive Binary Grey Wolf Optimizer To Solve The Feature Selection Problem in EMG Signals Classification. *Computers*, 7(4), 58.

Subasi, A. (2013). Classification of EMG Signals Using PSO Optimized SVM for Diagnosis Of Neuromuscular Disorders. *Computers in biology and medicine*, 43(5), 576-586.

Too, J., Abdullah, A. R., ve Mohd Saad, N. (2019). Hybrid Binary Particle Swarm Optimization Differential Evolution-Based Feature Selection For EMG Signals Classification. *Axioms*, 8(3), 79.

Too, J., Abdullah, A. R., Mohd Saad, N., ve Tee, W. (2019). EMG Feature Selection And Classification Using A Pbest-Guide Binary Particle Swarm Optimization. *Computation*, 7(1), 12.

Sahu, P., Singh, B. K., ve Nirala, N. (2023). An Improved Feature Selection Approach Using Global Best Guided Gaussian Artificial Bee Colony For EMG Classification. *Biomedical Signal Processing and Control*, 80, 104399.

Jain, R., ve Garg, V. K. (2021, September). EMG Classification Using Nature-Inspired Computing And Neural Architecture. In *2021 9th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO)* (pp. 1-5). IEEE.

Farag, H. O., Awad, M. I., Baioumy, A. M., Shawky, A. A., Taha, A. A., Hassan, A. A., ... ve Salem, S. M. (2021, December). Electromyography Signal Classification Using Convolution Neural Network Architecture For Bionic Arm High Level Control. In *2021 16th International Conference on Computer Engineering and Systems (ICCES)* (pp. 1-6). IEEE.

Bittibssi, T. M., Genedy, M. A., ve Maged, S. A. (2021). sEMG Pattern Recognition Based On Recurrent Neural Network. *Biomedical signal processing and control*, 70, 103048.

Zhang, X., Chen, X., Li, Y., Lantz, V., Wang, K., ve Yang, J. (2011). A Framework For Hand Gesture Recognition Based On Accelerometer And EMG Sensors. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41(6), 1064-1076.

İnternet: van Nieuwenhoven, M. (2015). The Myo Armband. URL: <https://diystuff.nl/bio-medical/myo-armband/>, Son Erişim tarihi: 14.04.2025.

Rawat, S., Vats, S., ve Kumar, P. (2016, November). Evaluating and exploring the MYO ARMBAND. In *2016 International Conference System Modeling & Advancement in Research Trends (SMART)* (pp. 115-120). IEEE.

Benalcázar, Marco E., Andrés G. Jaramillo, A. Zea, Andrés Páez, and Víctor Hugo Andaluz. Hand Gesture Recognition Using Machine Learning And The Myo Armband. In *2017 25th European Signal Processing Conference (EUSIPCO)*, pp. 1040-1044. IEEE, 2017.

Sosin, I., Kudenko, D., ve Shpilman, A. (2018, November). Continuous Gesture Recognition From sEMG Sensor Data With Recurrent Neural Networks And Adversarial Domain Adaptation. In *2018 15Th International Conference On Control, Automation, Robotics And Vision (ICARCV)* (pp. 1436-1441). IEEE.

İnternet: nccvector. (2018a). Electromyography(EMG) Dataset. URL: <https://www.kaggle.com/datasets/nccvector/electromyography-emg-dataset>, Son Erişim tarihi: 22.07.2023.

Naseer, N., Ali, F., Ahmed, S., Iftikhar, S., Khan, R. A., & Nazeer, H. (2018, November). EMG Based Control Of İndividual Fingers Of Robotic Hand. In *2018 International Conference on Sustainable Information Engineering and Technology (SIET)* (pp. 6-9). IEEE.

İnternet: Rosenstein, N. (2018b). Myo-python. URL: <https://pypi.org/project/myo-python>, Son Erişim tarihi: 22.011.2023.

Öztürk, E. (2004). K-En Yakın Komşu Algoritmasında Ağırlıklı Öklid Mesafesi Ölçümüne Yenilikçi Bir Yaklaşım, Doktora Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.

Koklu, M., & Ozkan, I. A. (2020). Multiclass Classification Of Dry Beans Using Computer Vision And Machine Learning Techniques. *Computers and Electronics in Agriculture*, 174, 105507.

Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.

Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.

Karadağ, B. (2023). Yapay Zeka Teknolojileri ile Mobil Uygulamalarda Nesne Tanıma, Yüksek Lisans Tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya.

Kütük, R. (2024). Makine Öğrenmesi Yaklaşımlarından Random Forest Regressor(RF) Ve Decision Tree Regressor(DT) Modellerinin Akıllı Telefon Fiyatlarında Karşılaştırmalı Analizi, Yüksek Lisans Tezi, *Üsküdar Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.

LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep Learning. *nature*, 521(7553), 436-444.

Rumelhart, D. E., Hinton, G. E., ve Williams, R. J. (1986). Learning Representations By Back-Propagating Errors. *nature*, 323(6088), 533-536.

Gao, X., Li, W., Loomes, M., ve Wang, L. (2017). A Fused Deep Learning Architecture For Viewpoint Classification Of Echocardiography. *Information Fusion*, 36, 103-113.

Bayram, F. (2020). Derin Öğrenme Tabanlı Otomatik Plaka Tanıma. *Politeknik Dergisi*, 23(4), 955-960.

Gürsoy, M. İ. (2025). EMG Sinyalleri İle Derin Öğrenme Yöntemlerini Kullanarak El/Parmak Hareketi Tanıma. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 179-188.

Sparto, P. J., Parnianpour, M., Barria, E. A., ve Jagadeesh, J. M. (2000). Wavelet And Short-Time Fourier Transform Analysis Of Electromyography For Detection Of Back Muscle Fatigue. *IEEE Transactions on rehabilitation engineering*, 8(3), 433-436.

Zhang, X., Wang, Y., ve Han, R. P. (2010, August). Wavelet Transform Theory And Its Application in EMG Signal Processing. In *2010 Seventh International Conference on Fuzzy Systems and Knowledge Discovery* (Vol. 5, pp. 2234-2238). IEEE.

Lalitharatne, T. D., Hayashi, Y., Teramoto, K., ve Kiguchi, K. (2012, September). A Study On Effects Of Muscle Fatigue on EMG-based Control For Human Upper-Limb Power-Assist. In *2012 IEEE 6th International Conference on Information and Automation for Sustainability* (pp. 124-128). IEEE.

Phinyomark, A., Phukpattaranont, P., ve Limsakul, C. (2012). Feature Reduction And Selection For EMG Signal Classification. *Expert Systems With Applications*, 39(8), 7420-7431.

Phinyomark, A., Phukpattaranont, P., ve Limsakul, C. (2012). Fractal Analysis Features For Weak and Single-Channel Upper-Limb EMG Signals. *Expert Systems with Applications*, 39(12), 11156-11163.

Too, J., Abdullah, A. R., Mohd Saad, N., ve Tee, W. (2019). EMG Feature Selection And Classification Using A Pbest-Guide Binary Particle Swarm Optimization. *Computation*, 7(1), 12.

Li, W., Shi, P., ve Yu, H. (2021). Gesture Recognition Using Surface Electromyography And Deep Learning For Prostheses Hand: State-Of-The-Art, Challenges, And Future. *Frontiers in neuroscience*, 15, 621885.

Abdelouahad, A., Belkhou, A., Jbari, A., ve Bellarbi, L. (2018, April). Time And Frequency Parameters Of sEMG Signal—Force Relationship. In *2018 4th international conference on optimization and applications (ICOA)* (pp. 1-5). IEEE.

Yu, Y., Zhu, Y., Li, S., ve Wan, D. (2014). Time Series Outlier Detection Based On Sliding Window Prediction. *Mathematical problems in Engineering*, 2014(1), 879736.

Özsağlam, M. Y., ve Çunkaş, M. (2008). Optimizasyon Problemlerinin Çözümü İçin Parçacık Sürü Optimizasyonu Algoritması. *Politeknik Dergisi*, 11(4), 299-305.

Kennedy, J., ve Eberhart, R. (1995, November). Particle Swarm Optimization. In *Proceedings of ICNN'95-international Conference on Neural Networks* (Vol. 4, pp. 1942-1948). iee.

İşçimen, B. (2024). Yeni Bir Optimizasyon Algoritması EMEL: Hareketli Ve Sürekli Küçülen Katmanlarla Arama, Doktora Tezi, *Çukurova Üniversitesi Fen Bilimleri Enstitüsü*, Adana.

Altunkol, Y. (2022). Izgara Arama Ve Parçacık Sürüsü Optimizasyonunu Birleştiren Yeni Bir Algoritma İle Destek Vektör Makinelerinin Hiperparametre Optimizasyonu, Yüksek Lisans Tezi, *Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü*, Adana.

Alsabaawi, M. M. H. (2022). Evrişimli Sinir Ağı ve Parçacık Sürüsü Optimizasyonu Algoritması (Pso) Kullanarak Verimli İnşaat Maliyeti Tahmin Yazılımı, Yüksek Lisans Tezi, *Altınbaş Üniversitesi Lisansüstü Eğitim Enstitüsü*, İstanbul.

Kiran, M. S. (2015). TSA: Tree-Seed Algorithm For Continuous Optimization. *Expert Systems with Applications*, 42(19), 6686-6698.

Çınar, A. C. (2016). Ağaç-Tohum Algoritması İçin Cuda Tabanlı Bir Paralel Programlama Yaklaşımı, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.

Karakul, M. S., ve Gökçen, A. (2024). Finger Movement Recognition Using Machine Learning Algorithms With Tree-Seed Algorithm. *Turkish Journal Of Electrical Engineering And Computer Sciences*, 32(5), 718-731.

Aslan, M., Beskirli, M., Kodaz, H., ve Kiran, M. S. (2018). An İmproved Tree Seed Algorithm For Optimization Problems. *Int J Mach Learn Comput*, 8(1), 20-25.

Karakul, M. S., ve Gökçen, A. (2023, Ekim). EMG-based finger movement recognition and window size comparison. *BİLTEK-VIII International Symposium on Current Developments in Science, Technology and Social Sciences* (pp. 1142-1148), Paris, Fransa.

Karakul, M. S., ve Gokcen, A. (2023). Wavelet Transform Based Finger Movement Recognition. *Akıllı Sistemler ve Uygulamaları Dergisi*, 6(2), 21-26.

Antal, M., ve Nemes, G. (2016, May). Gender Recognition From Mobile Biometric Data. In *2016 IEEE 11th International Symposium On Applied Computational Intelligence And Informatics (SACI)* (Pp. 243-248). IEEE.

Ng, C. B., Tay, Y. H., ve Goi, B. M. (2015). A Review Of Facial Gender Recognition. *Pattern Analysis And Applications*, 18, 739-755.

Hu, J. (2018). An Approach To EEG-Based Gender Recognition Using Entropy Measurement Methods. *Knowledge-Based Systems*, 140, 134-141.

Cao, L., Dikmen, M., Fu, Y., ve Huang, T. S. (2008, October). Gender Recognition From Body. In *Proceedings Of The 16th ACM International Conference On Multimedia* (Pp. 725-728).

Mansanet, J., Albiol, A., ve Paredes, R. (2016). Local Deep Neural Networks For Gender Recognition. *Pattern Recognition Letters*, 70, 80-86.

Dhomne, A., Kumar, R., ve Bhan, V. (2018). Gender Recognition Through Face Using Deep Learning. *Procedia Computer Science*, 132, 2-10.

van de Wolfshaar, J., Karaaba, M. F., ve Wiering, M. A. (2015, December). Deep Convolutional Neural Networks And Support Vector Machines For Gender Recognition. In *2015 IEEE Symposium Series On Computational Intelligence* (Pp. 188-195). IEEE.

Alnuaim, A. A., Zakariah, M., Shashidhar, C., Hatamleh, W. A., Tarazi, H., Shukla, P. K., ve Ratna, R. (2022). Speaker Gender Recognition Based On Deep Neural Networks And Resnet50. *Wireless Communications And Mobile Computing*, 2022(1), 4444388.

Buyukyilmaz, M. ve Cibikdiken, A. O. (2016, December). Voice Gender Recognition Using Deep Learning. In *2016 International Conference On Modeling, Simulation And Optimization Technologies And Applications (MSOTA2016)* (Pp. 409-411). Atlantis Press.

Tsimperidis, I., Arampatzis, A., ve Karakos, A. (2018). Keystroke Dynamics Features For Gender Recognition. *Digital Investigation*, 24, 4-10.

Cabra, J. L., Mendez, D., ve Trujillo, L. C. (2018, May). Wide Machine Learning Algorithms Evaluation Applied To ECG Authentication And Gender Recognition. In *Proceedings of the 2018 2nd International Conference On Biometric Engineering And Applications* (Pp. 58-64).

Halim, K. Y., Nugrahadi, D. T., Faisal, M. R., Herteno, R., ve Budiman, I. (2023). Gender Classification Based On Electrocardiogram Signals Using Long Short Term Memory And Bidirectional Long Short Term Memory. *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika (JITEKI)*, 9(3), 606-618.

Khan, M. U., Saad, M., Aziz, S., Ch, J. M., Naqvi, S. Z. H., ve Qasim, M. A. (2020, June). Electrocardiogram Based Gender Classification. In *2020 International Conference On Electrical, Communication, And Computer Engineering (ICECCE)* (Pp. 1-6). IEEE.

Wang, P. ve Hu, J. (2019). A Hybrid Model For EEG-Based Gender Recognition. *Cognitive Neurodynamics*, 13(6), 541-554.

Zhang, J., Xu, H., Zhu, L., Kong, W., ve Ma, Z. (2019, November). Gender Recognition In Emotion Perception Using EEG Features. In *2019 IEEE International Conference On Bioinformatics And Biomedicine (BIBM)* (Pp. 2883-2887). IEEE.

Mohd Rosli, N. A. I., Abdul Rahman, M. A., Balakrishnan, M., Komeda, T., Mazlan, S. A., ve Zamzuri, H. (2017). Improved Gender Recognition During Stepping Activity For Rehab Application Using The Combinatorial Fusion Approach Of EMG And HRV. *Applied Sciences*, 7(4), 348.

Godiyal, A. K., Sharma, R., Joshi, D., ve Bhatia, D. (2013). Feasibility Of Facial EMG In Gender Classification During Speech Production. *Journal Of Medical Engineering & Technology*, 37(2), 86-90.

Lee, M., Lee, J. H., ve Kim, D. H. (2022). Gender Recognition Using Optimal Gait Feature Based On Recursive Feature Elimination In Normal Walking. *Expert Systems With Applications*, 189, 116040.



EK-1: Tezden Üretilen Yayınlar

- 1- Karakul, M. S., ve Gökçen, A. (2023, Ekim). EMG-based finger movement recognition and window size comparison. BİLTEK-VIII International Symposium on Current Developments in Science, Technology and Social Sciences (pp. 1142-1148), Paris, Fransa.
- 2- Karakul, M. S., ve Gokcen, A. (2023). Wavelet Transform Based Finger Movement Recognition. *Akıllı Sistemler ve Uygulamaları Dergisi*, 6(2), 21-26.
- 3- Karakul, M. S., ve Gökçen, A. (2024). Finger Movement Recognition Using Machine Learning Algorithms With Tree-Seed Algorithm. *Turkish Journal Of Electrical Engineering And Computer Sciences*, 32(5), 718-731.





TEKNOVERSİTE