

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

MAKİNE ÖĞRENMESİ, TOPOLOJİK VERİ ANALİZİ VE DERİN
ÖĞRENME MODELLERİ İLE EMG SİNYAL ANALİZİ

YÜKSEK LİSANS TEZİ

Emin MOLLAHASANOĞLU

HAZİRAN 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MAKİNE ÖĞRENMESİ, TOPOLOJİK VERİ ANALİZİ VE DERİN
ÖĞRENME MODELLERİ İLE EMG SİNYAL ANALİZİ**

Emin MOLLAHASANOĞLU

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"ELEKTRONİK YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 04 / 06 / 2024

Tezin Savunma Tarihi : 26 / 06 / 2024

Tez Danışmanı : Doç. Dr. Yusuf SEVİM

Trabzon 2024

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Elektrik Elektronik Mühendisliği Anabilim Dalında
Emin MOLLAHASANOĞLU Tarafından Hazırlanan**

**MAKİNE ÖĞRENMESİ, TOPOLOJİK VERİ ANALİZİ VE DERİN
ÖĞRENME MODELLERİ İLE EMG SİNYAL ANALİZİ**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 06 / 06 / 2024 gün ve 2056
sayılı kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Prof. Dr. Ayten ATASOY

Üye : Prof. Dr. Onur Özdal MENGİ

Üye : Doç. Dr. Yusuf SEVİM

**Prof. Dr. Asim KADIOĞLU
Enstitü Müdürü**

ÖNSÖZ

“Makine Öğrenmesi, Topoloji Veri Analizi ve Derin Öğrenme Modelleri ile EMG Sinyal Analizi” başlıklı bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Bu tez çalışması kapsamında bilgi birikimleri, önerileri ve yönlendirmeleri ile bana her fırsatta destek olan değerli danışmanım Sayın Doç. Dr. Yusuf SEVİM’e içtenlikle teşekkür ederim.

Ayrıca tez çalışmam süresince yanımda olan, değerli vakitlerini benimle paylaşan, bana sağladıkları yardım ve motivasyon için Öğr. Gör. Miraç ÖZTÜRK, Arş. Gör. Burak AYDIN ve Arş. Gör. Samet DİNÇER’e teşekkürlerimi sunarım.

Yüksek Lisans eğitimim sürecinde bana olan bütün yardım ve katkılarından dolayı bölümümdeki bütün hocalarım ve değerli araştırma görevlisi arkadaşlarıma teşekkür ederim.

Son olarak hayatımın her anında benimle olan, desteklerini hiçbir zaman esirgemeyen, bütün tecrübeleri ile aldığım her kararda arkamda olan, maddi ve manevi destekleri ile bugünlere gelmemde en büyük katkıya sahip olan aileme teşekkürü bir borç bilirim.

Tamamladığım bu tez çalışmasının literatüre ve gelecekte yapılacak olan çalışmalara katkı sağlamasını temenni ederim.

Emin MOLLAHASANOĞLU

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Makine Öğrenmesi, Topoloji Veri Analizi ve Derin Öğrenme Modelleri ile EMG Sinyal Analizi” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Yusuf SEVİM’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 26/06/2024

Emin MOLLAHASANOĞLU

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER VE KISALTMALAR DİZİNİ	XII
1. GENEL BİLGİLER	1
1.1. Literatür Araştırması	3
1.2. Elektromiyografi Sinyalleri	6
1.3. EMG Sinyallerin Karakteristikleri	6
1.4. EMG Sinyalinin Kayıt Edilmesi ve Elektrot Çeşitleri	8
1.5. Veri Seti Tanıtımı.....	9
1.6. Özellik Çıkarımı	10
1.6.1. Ortalama Mutlak Değer	11
1.6.2. Kök Ortalama	11
1.6.3. Sıfır Geçiş Noktası	11
1.6.4. Dalga Uzunluğu	11
1.6.5. Willison Genliği.....	12
1.6.6. Eğim İşareti Değişimi	12
1.6.7. AR Katsayıları.....	13
1.6.8. Dalgacık Dönüşümü.....	13
1.6.9. Stockwell Dönüşümü	14
1.7. Makine Öğrenmesi	14
1.7.1. Denetimli Öğrenme	15
1.7.2. Denetimsiz Öğrenme.....	16
1.7.3. Yarı Denetimli Öğrenme.....	16
1.7.4. Pekiştirmeli Öğrenme	16
1.8. Denetimli Öğrenmeye Genel Bir Bakış.....	17
1.8.1. K-En Yakın Komşu.....	17

1.8.2.	Destek Vektör Makineleri	18
1.8.3.	Karar Ağaçları	19
1.8.4.	Navie Bayes	20
1.9.	Topolojik Veri Analizi	20
1.9.1.	Makine Öğrenmesinde Topolojik Veri Analizi	21
1.9.2.	Simplikal Kompleks.....	22
1.9.3.	Betti Sayıları	23
1.9.4.	Kalıcı Homoloji.....	24
1.9.5.	Barkod ve Kalıcılık Diyagramları	27
1.9.6.	Topolojide Mesafe Ölçümü	29
1.10.	Derin Öğrenme ve Topolojik Veri Analizi.....	30
1.10.1.	Evrişimsel Sinir Ağları.....	31
1.10.2.	Derin Öğrenme Modelleri	33
1.10.3.	Kapsül Ağı (CapsNet).....	36
2.	YAPILAN ÇALIŞMALAR.....	38
2.1.	Makine Öğrenmesi Algoritmaları ile EMG Sinyal İşleme.....	38
2.1.1.	Veri Ön İşleme	38
2.1.2.	Pencereleme	39
2.1.3.	Sensör Seçimi.....	40
2.1.4.	Özellik Çıkarımı ve Sınıflandırma	43
2.2.	Topolojik Veri Analizi İle EMG Sinyal İşleme	54
2.2.1.	Barkod ve Kalıcılık Diyagramlarının Elde Edilmesi	56
2.3.	Derin Öğrenme Algortimaları ile EMG sinyal İşleme	63
2.3.1.	EMG Sinyalinin Görüntüye Dönüştürülmesi.....	63
2.3.1.	Derin Öğrenme Modelleri ile Özellik Çıkarımı	64
2.3.2.	Kapsül Ağı Modeli.....	65
2.3.1.	Derin Öğrenme Modeli için Parametrelerin Düzenlenmesi.....	66
2.3.2.	Korelasyon Matrislerinin Isı Haritalarının Çıkarılarak Derin Öğrenme Modelleri ile Sınıflandırılması	71
3.	SONUÇLAR.....	73
4.	ÖNERİLER.....	76
5.	KAYNAKLAR	77
	ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

MAKİNE ÖĞRENMESİ, TOPOLOJİK VERİ ANALİZİ VE DERİN ÖĞRENME MODELLERİ İLE EMG SİNYAL ANALİZİ

Emin MOLLAHASANOĞLU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Yusuf SEVİM
2024, 82 Sayfa

Bu tez çalışmasında Elektromiyografi (EMG) sinyallerinin etkili bir şekilde analizi amaçlanmıştır. Bu doğrultuda geleneksel makine öğrenmesi algoritmaları, topolojik veri analizi ve derin öğrenmeye dayalı algoritma yöntemleri içeren 3 farklı yaklaşım kullanılmıştır. İlk yöntemde, EMG sinyallerinden farklı özellikler çıkarılmıştır. Bu özelliklerin tek tek, ikili, üçlü ve dörtlü kombinasyonları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Ayrıca, 128 sensör içinde elektriksel aktivite bilgisi az olan sensörler belirlenerek elemeye tabi tutulmuştur. Seçilen 120 sensör ve ikili özellik kombinasyonunda %99.75 başarımla elde edilmiştir. İkinci yöntemde, EMG verisinin barkod diyagramı, kalıcılık diyagramı ve simpleks değerleri hesaplanarak topolojik yapısı analiz edilmiştir. 0.boyut yaşam süreleri özellik olarak kullanıldığında %70.26 başarımla elde edilmiştir. Üçüncü yöntemde ise EMG verisi sürekli dalgacık dönüşümü yöntemi ile görüntüye dönüştürülmüştür ve önceden eğitilmiş derin öğrenme modelleri kullanılarak özellik çıkarımı gerçekleştirilmiştir. Elde edilen özellikler, kapsül ağına girdi olarak verilerek sınıflandırma işlemi gerçekleştirilmiştir. Bu yöntemle %97.32 başarımla elde edilmiştir. Aynı zamanda EMG verisinden elde edilen korelasyon ısı haritaları görüntü olarak kullanılarak derin öğrenme modellerine girdi olarak verilip sınıflandırmaya tabi tutulmuştur.

Anahtar Kelimeler: EMG, Topolojik veri analizi, Makine öğrenmesi, Derin öğrenme, Sürekli dalgacık dönüşümü

Master Thesis

SUMMARY

EMG SIGNAL ANALYSIS WITH MACHINE LEARNING, TOPOLOGICAL DATA ANALYSIS AND DEEP LEARNING MODELS

Emin MOLLAHASANOĞLU

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical-Electronics Engineering Graduate Program
Supervisor: Assoc. Prof. Yusuf SEVİM
2024, 82 Pages

In this thesis study, it is aimed to analyze Electromyography (EMG) signals effectively. In this regard, three different approaches were used, including traditional machine learning algorithms, topological data analysis and deep learning-based algorithm methods. In the first method, different features are extracted from EMG signals. Classification was carried out using individual, double, triple and quadruple combinations of these features. Additionally, among the 128 sensors, sensors with low electrical activity information were identified and eliminated. 99.75% accuracy was achieved in the selected 120 sensor and binary feature combinations. In the second method, the topological structure of the EMG data was analyzed by calculating the barcode diagram, persistence diagram and simplex values. When 0th dimension lifetimes were used as features, 70.26% accuracy was obtained. In the third method, EMG data was converted to images using the continuous wavelet transform method and feature extraction was performed using pre-trained deep learning models. The obtained features were given as input to the capsule network and the classification process was carried out. A success rate of 97.32% was achieved with this method. At the same time, correlation heat maps obtained from EMG data were used as images and given as input to deep learning models and subjected to classification.

Key Words: EMG, Topological data analysis, Machine learning, Deep learning, Continuous wavelet transform

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Motor birimleri kontrol sistemi (Atkinson, 2018)	2
Şekil 2. 4 Farklı sınıfa ait EMG sinyalleri	7
Şekil 3. DB-a ve DB-b veri tabanlarındaki el hareketleri (Du vd., 2017)	9
Şekil 4. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki.....	14
Şekil 5. Öklid hesaplamasına göre k-EYK tekniği	18
Şekil 6. Temsili bir DVM örneği	19
Şekil 7. Karar ağacı örneği.....	19
Şekil 8. Ham veriden nokta bulutu elde edilmesi	21
Şekil 9. Simpleks yapıları	23
Şekil 10. Betti sayıları.....	24
Şekil 11. Nokta bulutundan dayanıklı homoloji oluşumunun gösterimi (a) veri setinin nokta bulutu şeklindeki gösterimi, (b) ölçek değeri a iken homoloji gösterimi, (c) ölçek değeri b iken homoloji gösterimi, (d) ölçek değeri c iken homoloji gösterimi	26
Şekil 12. Barkod ve kalıcılık diyagramları	28
Şekil 13. Evrişimsel sinir ağı	31
Şekil 14. Evrişimsel katman	32
Şekil 15. Havuzlama katmanı	32
Şekil 16. Tam bağlantılı katman	33
Şekil 17. Özellik çıkarımı EfficientNet Katmanları	34
Şekil 18. Özellik çıkarımı için VGG19 katmanları	35
Şekil 19. Kapsül Ağı.....	37
Şekil 20. Pencereleme yöntemi.....	40
Şekil 21. Tüm sensörlerin varyans değerleri.....	41
Şekil 22. Yüzey EMG sensörlerinin dairesel grafiği	43
Şekil 23. EMG sinyali için topolojik veri analizi şeması.....	55
Şekil 24. 1.Sınıfa ait EMG verisinin simplekslerinden oluşan homoloji grubu	56
Şekil 25. 1.Sınıfa ait bir örneğin barkod diyagramı.....	57
Şekil 26. 2.Sınıfa ait bir örneğin barkod diyagramı.....	58
Şekil 27. 3.Sınıfa ait bir örneğin barkod diyagramı.....	59
Şekil 28. 1.Sınıfa ait bir örneğin kalıcılık diyagramı.....	60

Şekil 29.	2.Sınıfa ait bir örneğin kalıcılık diyagramı.....	61
Şekil 30.	1.Sınıfa ait bir örneğin kalıcılık diyagramı.....	61
Şekil 31.	Sistem akış şeması	63
Şekil 32.	Birinci sınıfa ait ham EMG verisi (a) ve skalogram görüntüsü (b)	64
Şekil 33.	EfficientNetB0 için eğitim ve doğrulama doğrulukları	67
Şekil 34.	EfficientNetB0 için eğitim ve doğrulama kayıpları	68
Şekil 35.	EfficientNetB4 için eğitim ve doğrulama doğrulukları	68
Şekil 36.	EfficientNetB4 için eğitim ve doğrulama kayıpları	69
Şekil 37.	VGG19 için eğitim ve doğrulama doğrulukları.....	69
Şekil 38.	VGG19 için eğitim ve doğrulama kayıpları	70
Şekil 39.	Korelasyon matrisinin ısı haritası	72

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. En düşük 40 sensörün sensör sırası ve varyans değeri	42
Tablo 2. Seçili 80 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları	46
Tablo 3. Seçili 120 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları	48
Tablo 4. Seçili 128 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları	49
Tablo 5. Seçili 80 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları.....	50
Tablo 6. Seçili 120 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları.....	51
Tablo 7. Seçili 128 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları.....	52
Tablo 8. Seçili 80 sensörde özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları.....	53
Tablo 9. Seçili 120 sensörde özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları	53
Tablo 10. Seçili 128 sensörde özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları	54
Tablo 11. Topolojik özellikler kullanılarak sınıflandırılan EMG verisinin sınıflandırma sonuçları	62
Tablo 12. Kapsül ağında kullanılan parametreler ve değerleri	66
Tablo 13. Farklı özellik çıkarma modelleri için eğitim, başarımlar oranları ve kayıpları	70
Tablo 14. Korelasyon matrislerinden elde edilen ısı haritalarının derin öğrenme modeli için eğitim, doğrulama doğrulukları ve kayıpları	72
Tablo 15. Önerilen tüm yaklaşımlar ve başarımlar yüzdeleri	74

SEMBOLLER VE KISALTMALAR DİZİNİ

β	: Betti Sayısı
AR	: AutoRegressive
DB	: Dalgaboyu
DD	: Dalgacık dönüşümü
DİA	: Derin inanç ağı
DNN	: Tam bağlantılı sinir ağı
DVM	: Destek vektör makinesi
EEG	: Elektroensefalografi
EİD	: Eğim işareti değişimi
EKG	: Elektrokardiyografi
EMG	: Elektromiyografi
ESA	: Evrişimli sinir ağı
Hz	: Hertz
IBM	: International Business Machines
İDDA	: İlişkisiz doğrusal diskriminant analiz
KA	: Karar ağaçları
kEMG	: Kinesiyoloji elektromiyografi
k-EYK	: k- En Yakın Komşu
KO	: Kök ortalama
MB	: Motor birim
MKS	: Markov karar süreci
mV	: Milivolt
NB	: Navie Bayes
nEMG	: Nörolojik elektromiyografi
OMD	: Ortalama mutlak değer
ReLU	: Rectified Linear Unit
SD	: Stockwell dönüşümü
sEMG	: Yüzey elektromiyografi
SGA	: Sıfır geçiş alanı
SGD	: Sıfır geçiş diferansiyeli

SGDK	: Sıfır geiř diferansiyel konumları
SGFKÇ	: Sıfır geiř çoğaltılmış diferansiyel konumları
SGN	: Sıfır geiř noktası
SGO	: Sinyal gürültü oranı
SS	: Standart sapma
TBA	: Temel bileřen analizi
TVA	: Topolojik veri analizi
V	: Volt
WG	: Willison genlięi
YSA	: Yapay sinir aęı
YZ	: Yapay zeka


1. GENEL BİLGİLER

Günümüzde tıp alanında yapılan çalışmalara bakıldığında en yoğun çalışmaların tıp mühendislik etkileşimli olduğu görülmektedir. Özellikle hastalıkların tanı ve tedavisinde sıkça mühendislik ürünü olan çalışmalar kullanılmaktadır. Bu çalışmalardan biri de insan vücudunun farklı bölgelerinde bulunan elektrik sinyallerinin elde edilmesi ve işlenmesi üzerinedir. Vücudun farklı yerlerinde var olan elektrik sinyalleri bulunduğu bölgelere göre çeşitlilik gösterir (James & Hesse, 2004). Kalp ve civarı üzerinde meydana gelen elektriksel faaliyetin elde edilmesi işlemine Elektrokardiyografi (EKG), bu işlemin beyinde gerçekleşmesi Elektroensefalografi (EEG), sinir ve çizgili kaslarda gerçekleşmesi ise Elektromiyografi (EMG) olarak adlandırılır (Jin vd., 2017). Bu tez kapsamında EMG sinyali analiz edilmiştir.

EMG sinyalleri, kas aktivitelerini ölçmek ve analiz etmek için bugünlerde yaygın bir kullanıma sahip olup aynı zamanda rehabilitasyon ve insan-makine etkileşimi gibi birçok alanda kullanılmaktadır. Ayrıca günlük hayattaki işlemleri kolaylaştırmak için kontrol-kumanda uygulamalarında yer almaktadırlar. Son zamanlarda özellikle el hareketi sınıflandırması, yüz hareketi tanıma, miyoelektrik protezler, kas yorgunluğu arayüzleri vb. alanlarında kullanılmaktadırlar (Rodríguez-Tapia vd., 2020). EMG tabanlı sınıflandırma algoritmalarının performansını arttırmak, bu alanda yapılan çalışmaların başarı potansiyelini de arttırabilir. Bu kapsamda EMG sinyallerinin doğru ve hassas bir şekilde sınıflandırılması, bu alanda yapılan çalışmaların etkin bir hale gelmesi için ana unsurlardan birini oluşturmaktadır. EMG sinyallerinin insan vücudu üzerinde oluşması durumunun kavranılması bu sinyallerin analiz edilmesini kolaylaştırmaktadır.

İnsan vücudu, üzerindeki bir kas büyüklüğüne bağlı olarak bir dizi Motor Birim (MB) içerir ve MB kasın nöral kontrolünden sorumlu olan en küçük fonksiyonel birimdir (Kleissen vd., 1998). MB'in görevi üst motor nöronları ile kas hareketlerini kontrol etmektir (M. Chen vd., 2022). Dokular kas liflerindeki elektriksel iletkenliği desteklerken, aynı zamanda liflerin depolarizasyonunu da sağlar. Motor nöronlarının uzun aksonları vardır. Sinir hücrelerinin bir parçası olarak çalışırlar (Z. Chen vd., 2020). Her bir akson aynı uç plakadaki farklı kas liflerine bağlanır. Genellikle motor nöronlar kas gruplarını desteklemek için ortada bulunan liflerdir. Kaslar deri dokusu ve tüm vücut organları ile duyuşal iletişim kurar (Al-Jumaily & Olivares, 2009). Şekil 1'de gösterildiği gibi kas liflerinden gelen

elektriksel bir uyarı akson boyunca ilerler ve motorun ucuna yapışır. Bu kısım uç plak olarak bilinir. İmpulsun ulaşmasından önce depolarizasyon dalgalarının, kas liflerinin her iki ucu boyunca yayılmasına neden olan nörotransmiterler ortaya çıkar.



Şekil 1. Motor birimleri kontrol sistemi (Atkinson, 2018)

EMG sinyallerini sınıflandırmak için farklı teknikler uygulanmaktadır. En sık uygulanan teknikler: Zaman ve frekans analizleri, makine öğrenimi sınıflandırma algoritmaları, derin öğrenme modelleri gibi yöntemlerdir (Marchant, 2003). Zaman ve frekans analizi yöntemlerine bakıldığında; zirve ve tepe analizi, zaman alanı işleme, istatistiksel özellikler kullanma gibi yöntemler kullanılmıştır. Bu çalışmalarda EMG sinyallerinin genliklerinin en yüksek ve en düşük değerleri, tepe noktaları arasındaki zaman farkı, sinyallerin altında kalan alan hesapları, ortalama, standart sapma, sıfır geçiş noktaları, fourier dönüşümleri, motor birim potansiyelleri gibi değer ve yöntemler kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir (Zawawi vd., 2020). Önceden eğitilmiş derin öğrenme modelleri kullanılarak da EMG sinyallerinin analizi gerçekleştirilmiştir. Bu çalışmalarda EMG sinyalleri ya da bu sinyallerin görüntüye çevrilmiş yapısından özellikler çıkarılarak derin öğrenme modelleri ile analiz yapılmıştır. Son zamanlarda Topolojik Veri Analizi (TVA) yöntemi de sinyal işleme ile ilişkilendirilmiştir. Biyomedikal verilerin

topolojik yapıları incelenerek veri analizleri yapılmaya başlanmıştır. TVA veri kümesinin topolojik yapılarını anlamak için geometri esaslı matematiksel yöntemleri ele alır. Karmaşık ve yüksek boyutlu verilerde etkili olan bir analiz yöntemidir. Son zamanlarda boyut azaltma, sınıflandırma, kümeleme gibi makine öğrenmesi alanlarında kullanılmaktadır (Hensel vd., 2021).

1.1. Literatür Araştırması

EMG, EKG ve EEG gibi biyomedikal sinyalleri şekilsel ve biyolojik köken olarak farklılık gösterdiklerinden dolayı analiz edilmelerinde farklı yöntemler kullanılmaktadır. Bu kısımda literatürde yer alan ilgili çalışmalara yer verilmiştir.

EMG sinyal analizinde makine öğrenmesi tabanlı çalışmalara bakıldığında; Benalcázar ve arkadaşları 5 farklı el hareketini k En Yakın Komşu (k-EYK) sınıflandırma algoritması ve dinamik sarma yöntemi kullanılarak sınıflandırılmıştır (Benalcázar vd., 2017). Daha sonra başarımları MYO (kas) kol bandı sisteminin başarımları ile karşılaştırılmıştır. Sınıflandırma modellerinin başarımları %86 çıkarken MYO sisteminin başarımları %83 çıkmıştır. Bir diğer çalışmada sinyallerin hem zaman alanında hem de frekans alanında lokalize olan dalgacık katsayılarına bölündüğü bir sinyal işleme tekniği olan dalgacık ayrıştırmasını kullanılmıştır (Anil & Sreeletha, 2018). Negi ve arkadaşları EMG sinyallerinin özellik çıkarımı ve sınıflandırılması, özellik azaltma amacıyla Temel Bileşen Analizi (TBA) ve İlişkisiz Doğrusal Diskriminant Analizi (İDDA) kullanılarak gerçekleştirdiler ve daha sonra farklı hareketleri gerçek zamanlı olarak tanımak için bir sınıflandırma algoritması olan Destek Vektör Makineleri (DVM) kullandılar (Negi vd., 2016). Bir başka çalışmada elin serbest bırakılması ve elin kapatılması olarak iki sınıfın analizi gerçekleştirilmiştir (Brownlee, 2016). Bu çalışmada özellik olarak, ortalama, varyans, kurtosis ve skewness özellikleri kullanılmıştır. k-EYK ve DVM sınıflandırıcıları kullanılarak %96.58 başarımları elde edilmiştir. Devaraj ve Nair ham EMG sinyalinden çıkardığı 8 farklı zaman özelliğini kullanarak analiz yapmışlardır (Devaraj & Nair, 2020). Arland ve arkadaşları çalışmasında Myo kol bandı ile kaydettiği EMG verilerini k-EYK ve Karar Ağaçları (KA) algoritmalarını kullanarak %95'in üzerinde bir başarımları elde etmişlerdir (Arland vd., 2023). Bir diğer çalışmada 10 denekten elde edilen 6 farklı el hareketini sınıflandırmak için iki farklı yöntem sunulmuştur (Mobarak vd., 2014). İlk yöntemde dalgacık katsayılarının varyansına dayalı bir özellik vektörü kullanırken ikinci

yöntemde boyutsallığın azalmasına odaklanan bir TBA işlemini dikkate alındı. İlk yöntemde hem geçici hem de sürekli durumlar için uygulanarak sırasıyla 89.43 ± 2.05 ve 91.86 ± 3.17 ortalama sınıflandırma başarımı elde edildi. Khezri ve Jahed yüzey elektrotlarla toplanan EMG sinyallerini TBA’da boyut azaltarak bulanık sınıflayıcı ile sınıflandırma işlemi gerçekleştirmişlerdir (Khezri & Jahed, 2007). Luo ve arkadaşları ise yüzey elektrotlarla ön koldan alınan EMG işaretlerinin güç spektrumu katsayılarını ve bayes istatistiksel algoritmasını kullanarak sınıflandırma işlemi yaptılar (Luo vd., 2004). Bu çalışma sonucunda %84 oranında doğrulukla sınıflama başarımı elde etmişlerdir.

Son yıllarda topolojik veri analizi, makine öğrenmesi, derin öğrenme ve sinyal işleme gibi alanlarda önemli bir kullanım alanı bulmuştur. Bu kapsamda Hofer ve arkadaşları çalışmasında topolojik özellikleri derin sinir ağına girdi olarak verdiler (Hofer vd., 2018). 2D nesne şekilleri ve sosyal ağ grafikleri üzerinde yaptıkları bu çalışma yaklaşımın çok yönlülüğünü gösterdi. Bir diğer çalışmada değişmezlik teorisi kullanılarak barkod uzayı elde edildi (Adcock vd., 2013). Barkodları sabit boyutlarda vektörlere eşlediler ve makine öğrenme tekniği olan DVM ile sınıflandırma işlemini gerçekleştirdiler. Farklı bir yaklaşım olarak Burrello ve arkadaşları topolojiye dayalı özellikler ile makine öğrenmesi algoritmalarını kullanarak akıllı şebekelerde enerji hattı iletişim kalitesini tahmin ettiler (Burrello vd., 2022). Guo ve diğerleri ise topolojik veri analizini yüksek boyutlu uzaylardaki bilinmeyen şekilleri gözlemlenen veri örneklerinden yeniden oluşturmak için kullandılar ve Sparse-TVA algoritması ile TVA’nın ana şekil tanımlayıcılarını kullanarak seyrek piksel örnekleri seçerek, insan postür tanıma ve görüntü doku sınıflandırması gibi problemlerde umut vadettiğini gösterdiler (Guo vd., 2014).

EMG sinyallerinin işlenmesinde geleneksel makine öğrenmesi algoritmaları ve yeni bir yaklaşım olan topolojik veri analizinin yanı sıra yapay sinir ağlarından olan derin öğrenme algoritmaları da sıkça kullanılmaktadır. EMG sinyalleri hem zaman serisi hem de görüntüye çevrilmiş hali ile derin öğrenme algoritmalarına girdi olarak verilebilmektedir. Derin öğrenme algoritması ile işlenen EMG sinyalleri yüksek başarımlı oran ile sınıflandırılabilir. Bu alanda yapılan çalışmalara bakıldığında; Fukano ve arkadaşları yaptıkları çalışmada 53 farklı el hareketini Evrişimli Sinir Ağı (ESA) girdisi olarak kullanarak EMG sinyallerini sınıflandırmışlardır (Fukano vd., 2021). 53 hareketin tamamında %60’ın üzerinde bir başarımlı elde etmişlerdir. Özdemir ve arkadaşları ise 4 kanallı 7 farklı el hareketinin spektrogram görüntülerini alarak ve ResNet mimarisinde eğiterek yüksek bir başarımlı elde etmişlerdir (Ozdemir vd., 2020). Bir başka çalışmada EMG

sinyallerini sınıflandırmak için Deep Belief Network (DBN) modelini kullanılmış ve %90.66 gibi yüksek bir başarımla elde edilmiştir (Zhang vd., 2019). Bir başka çalışmada ise 8 farklı üst ekstremit el hareketinden oluşan veri setini tek kanallı ve çoklu ESA modeli kullanılarak sınıflandırılmış ve %94.4 başarımla elde edilmiştir (Han vd., 2021). Chung ve Benalcázar kendi kaydettikleri oldukça küçük bir veri seti ile ileri beslemeli yapay sinir ağı kullanmışlardır (Chung & Benalcázar, 2019). Detaylı mimariyi sağlayamadılar ve küçük veri setlerinde %85 başarımla elde ettiler. Côté-Allard ve diğerleri sürekli dalgacık dönüşümünü ön işleme olarak kullandılar ve bir ESA sınıflandırıcı kullanarak NinaPro DB6 veri seti üzerinde %68.98 başarımla elde ettiler (Côté-Allard vd., 2019). Burrello ve arkadaşları daha önce ifade edilen aynı çalışma içerisinde de NinaPro DB6 EMG veri setinde herhangi bir ön işleme yapmadan, veri setini sınıflandırmak için tek boyutlu bir ESA katmanı ve birden fazla öz-dikkat katmanı kullandılar. En yüksek %65.73 başarımla elde ettiler (Burrello vd., 2022). Nazari ve arkadaşları ise Mendeley veri setini sınıflandırmak için ön işleme adımı olarak filtreleme ve bir ESA modeli kullandılar. Ulaştıkları en yüksek başarımla %89.5 oldu (Nazari vd., 2022).

Bu tez çalışması kapsamında EMG sinyallerinin geleneksel makine öğrenme algoritmalarının yanında, topolojik veri analizi ve derin öğrenme tabanlı sinyal, görüntü işleme yaklaşımları kullanılarak analiz edilmesi amaçlanmıştır. Ayrıca, EMG sinyallerinin ön işleme tabii tutulmalarının özellik çıkarma ve sınıflandırma işlemleri üzerlerine etkisi incelenmiştir.

İlk çalışma EMG sinyallerinin geleneksel makine öğrenmesi algoritmaları kullanılarak sınıflandırılmasına dayanmaktadır. Öncelikle veri ön işleme tabii tutuldu. 128 sensör içerisinde elektriksel aktivite bilgisi az olan sensörler belirlenerek varyans değeri düşük olan sensörlerin eleme işlemi gerçekleştirildi. Daha sonra farklı özellikler ve bu özelliklerin kombinasyonları kullanılarak özellikler çıkarıldı. Son olarak k-EYK sınıflandırma algoritması ile sınıflandırma işlemi gerçekleştirildi.

Bir diğer çalışma TVA ile EMG verisi, uzayda bir nokta bulutu ile temsil edildi. EMG sinyalinin barkod ve kalıcılık diyagramları elde edildi. Veri setindeki her bir örneğin simpleks değerleri ile betti sayıları hesaplanarak özellik olarak kullanıldı ve sınıflandırma işlemine tabii tutuldu. Ayrıca TVA mesafe algoritması ile veriden elde edilen ısı haritaları, görüntü işleme teknikleri kullanılarak derin öğrenme algoritmalarıyla sınıflandırıldı.

Üçüncü yaklaşımda ise, EMG verisi sürekli dalgacık dönüşümü tekniği kullanılarak görüntüye çevrilmiştir. Görüntüye dönüştürülen verinin özellikleri, önceden eğitilmiş derin

öğrenme modelleri kullanılarak çıkarılmış ve daha sonra kapsül ağına girdi olarak verilerek sınıflandırılmıştır.

Bu üç yaklaşım birbiriyle karşılaştırılmış ve artı ve eksi yönleri incelenmiştir.


1.2. Elektromiyografi Sinyalleri

İnsanların hareket kontrol sistemini ve yaşam kalitelerini arttırmak için biyomedikal sinyaller üzerinde çalışmalar gerçekleştirilmiştir. Bu sinyaller vücudunun herhangi bir kısmında (organında) meydana gelen elektrik sinyallerinin bir birleşimi olarak düşünülebilir. EMG, EKG ve EEG biyomedikal sinyallere örnek olarak gösterilebilir. Bu sinyaller kas aktivitelerini, beyin hastalıklarını, kalp hastalıklarını ve daha fazlasının teşhis ve tedavi etmek için kullanılmaktadır (Luca, 1997). EMG sinyalleri biyomedikal sinyallerinin temel türlerinden birisidir. EMG sinyalleri sinir sistemi tarafından üretilir ve kasların fizyolojik yapısına göre çeşitlilik gösterir. EMG sinyalleri geniş çapta araştırılmış, kullanılmış ve uygulanmıştır. Yaygın olarak kullanılan elektrofizyolojik çalışmaların temel ürünlerinden birisidir. Kas aktivitelerini, genliklerini, fazlarını, özelliklerini ve daha fazlasını kayıt altına almak için biyo-sinyal olarak EMG sinyalleri kullanılmaktadır. EMG verileri genel olarak kasların aktivite veya dinlenme durumlarında oluşmaktadır. EMG temel olarak kas aktivitelerinin miyoelektrik dalgalarını tespit ve analiz etmek için kullanılır (Anam & Al-Jumaily, 2017). Yüzey elektromiyografi (sEMG), kinesiyoloji elektromiyografi (kEMG) ve nörolojik elektromiyografi (nEMG) olmak üzere farklı EMG türleri mevcuttur. sEMG klinik analiz için önemli bir araç iken kEMG kas hareketleri analiz etmede, nEMG ise nöromüsküler sistemlerde kullanılmaktadır. sEMG, iskelet kasının fizyolojisi ve morfolojisine yakından benzeyecek şekilde oluşturulmuş bir model kullanılarak, yaygın olarak kullanılan elektrotların çizgi kaynak modelleri ile birleştirilerek ve klinik çalışmalarda tutarlı bir şekilde konumlandırılarak üretilir (Hamilton-Wright & Stashuk, 2005).

1.3. EMG Sinyallerin Karakteristikleri

EMG sinyalleri rastgele sinyallerdir. Kaslarda rastgele bir şekilde oluşurlar. Genlik aralığı 10mV (tepeden tepeye) veya etkin değer olarak 0 mV ile 1.5 mV arasında olabilir. Sinyalin zamanla değişimi EMG'nin standart sapması olarak tanımlanır. Frekans aralığı 0

ila 500 Hz, gürültü enerjisi aralığı ise 50 ile 150 Hz arasındadır (Clancy vd., 2002). EMG sinyalleri farklı dokulardan geçerken gürültü oluşturur. Bu gürültü EMG sinyallerini etkileyecek bir elektrik sinyalidir. Diğer bir gürültü ise, elektronik teçhizatlar tarafından oluşturulur ve ortadan kaldırılamaz. Fakat yüksek kalitedeki elektronik bileşenler bunu azaltabilir. EMG sinyalini etkileyebilecek diğer etkenler hareket bileşenleridir. EMG işaretine uygun filtreleme işlemleri yapılarak sinyallerdeki gürültü oranı minimize edilebilir. Şekil 2’de tez kapsamında kullanılan veri setinden elde edilen EMG sinyalleri görünmektedir. Grafiklerde de görüldüğü gibi veri setindeki 4 farklı sınıfa ait EMG sinyalleri verilmiştir. Yatay eksen, verinin örnek uzunluğunu belirtirken dikey eksen verinin genliğini belirtmektedir. Örnek uzunluğu farklı veri seti ve çalışmalarda değişiklik gösterebilmektedir.



Şekil 2. 4 Farklı sınıfa ait EMG sinyalleri

1.4. EMG Sinyalinin Kayıt Edilmesi ve Elektrot Çeşitleri

EMG kasların elektriksel aktivitesini ölçerek, kasların ne kadar güçlü kasıldığını ve ne kadar hızlı gevşediğini belirlemeye yardımcı olur. EMG işaretlerinin kayıt altına alınması ve analizi, çeşitli uygulamalarda, özellikle tıbbi teşhis ve rehabilitasyon alanlarında önemli rol oynar.

Biyolojik işaretlerin, özellikle tıpta teşhise yönelik algılanabilmesi ve tedavi amacı için akım gönderilmesini sağlayan elemanlara elektrot adı verilir (Yazıcı, 2008). EMG sinyalleri de elektrotlar vasıtası ile alınabilmekte ve işaretlerin düzgün alınabilmesi için elektrotların kas üzerine doğru bir şekilde konumlandırılması gerekmektedir. Elektrotlardan alınan zayıf elektriksel sinyaller, bir yükselteç aracılığıyla güçlendirilir. Bu, sinyalin daha iyi okunmasını ve analiz edilmesini sağlar. Yükseltme işlemi, sinyalin istenen düzeyde olduğundan emin olmak için düzenli olarak kalibre edilmelidir. Elektrotlardan alınan sinyaller, istenmeyen gürültüyü filtrelemek için bir filtreleme işleminden geçirilir. Bu, EMG sinyalinin netliğini artırır ve yanlış sonuçların önlenmesine yardımcı olur. Filtrelenmiş ve amplifiye edilmiş EMG sinyali, bir veri kaydediciye aktarılır ve kaydedilir. Bu adım, sinyalin daha sonraki analiz için saklanmasını sağlar. Kaydedilen EMG verileri, uzmanlar tarafından analiz edilir ve yorumlanır. Bu, kas aktivitesinin desenlerini, gücünü ve diğer özelliklerini anlamak için yapılır. Analiz sonuçları, tıbbi teşhislerin yapılmasında veya rehabilitasyon programlarının oluşturulmasında kullanılabilir.

Kullanım yeri ve amacına göre çeşitli elektrot türleri mevcuttur. Elektrot türlerine yüzey elektrotları, dahili elektrotlar ve mikroelektrotlar örnek verilebilir. Yüzey elektrotları, biyolojik sinyallerin deri üzerinden toplanmasında kullanılırlar (Merlo vd., 2021). Dahili elektrotlar sinyalleri deri altından alırken kullanılırlar. İğne elektrotlar, dahili elektrotlara örnek olarak gösterilebilir. Mikroelektrotlar, hücre zarını delmeden uçları 0,05–10 μm arasında değişen boyutlarda olan ve hücre içine daldırılarak uyarılabilen hücrelerin elektriksel davranışlarını ölçmek için kullanılan elektrotlardır. Bu elektrotlar, hücreyi tahrip etmeden ve elektriksel davranışını bozmadan hücre içi ve dışı arasındaki potansiyel farkını ölçmeyi sağlar.

1.5. Veri Seti Tanıtımı

Bu tez çalışması kapsamında veri seti olarak CapgMyo adlı veri seti kullanılmıştır. CapgMyo, yüzey EMG hareket tanıma araştırmaları için özel olarak oluşturulan bir veri setidir (Du vd., 2017). Bu veri seti, hareket tanıma ve EMG sinyali analizi alanlarında ilerleme kaydetmek isteyen araştırmacılara büyük bir potansiyel sunmaktadır. CapgMyo veri seti, sağlıklı 23 katılımcının katılımıyla elde edilmiştir. Veri seti oluşturulurken her birinin yapısında 16 sensöre sahip 8 elektrot dizisi kullanılmıştır. Bu şekilde toplamda 128 kanallı veri toplanmıştır. Her bir elektrot 3mm çapa sahiptir. Katılımcıların yaşları 23 ile 26 arasında değişmektedir. Veri seti DB-a, DB-b, DB-c şeklinde 3 ayrı alt veri setinden oluşmaktadır. DB-a 23 katılımcının 18'inden alınan 8 farklı el hareketi içerir ve çalışmanın temelini oluşturan veri kümesidir. DB-b, aynı katılımcı grubunun 10'undan alınan 8 farklı el hareketlerinin EMG sinyallerini içerir. DB-c ise 23 katılımcının 10'undan alınan 12 farklı temel parmak hareketlerini içerir (Zecca vd., 2002). Bu veri seti, yüzey EMG tabanlı hareket tanıma alanında araştırma yapmak isteyenler için değerli bir kaynak olabilir ve çalışmanızın güvenli bir temelini oluşturabilir. Şekil 3'te DB-a ve DB-b veri tabanlarını oluşturan 8 farklı el hareketi gösterilmiştir.

Sınıf	Açıklama	Örnek	Sınıf	Açıklama	Örnek
1	Başparmak yukarı		5	Tüm parmaklar açık	
2	İşaret ve orta parmak yukarı, diğerlerinin kapatılması		6	Parmaklar yumruk şeklinde bükülmüş	
3	Yüzük ve küçük parmak yukarı, diğerlerinin kapatılması		7	İşaret parmağı yukarı, diğerlerinin kapatılması	
4	Başparmak kapalı, diğerleri yukarı		8	Uzatılmış parmakların addüksiyonu	

Şekil 3. DB-a ve DB-b veri tabanlarındaki el hareketleri (Du vd., 2017)

1.6. Özellik Çıkarımı

Özellik çıkarma, verileri işlemeye başlamadan önce gerçekleştirilmesi gereken önemli bir adımdır. EMG sinyalini doğrudan bir sınıflandırıcıya vermek mümkün olmadığından sinyalin daha küçük boyuta sahip bir özellik vektörüne dönüştürülmesi gerekmektedir. Zaman alanı, frekans alanı ve zaman-frekans alanı olmak üzere 3 farklı özellik grubu vardır. Sınıflandırma doğruluğunu arttırmak için özellik seçimi önemlidir. En yüksek sınıflandırma doğruluğunu elde etmek için en uygun özelliğin seçilmesi gerekmektedir. EMG özellikleri sinyallerin kasların durumu hakkında bilgi içerir ve nitelikleri segmentasyon süresinin uzunluğuna bağlıdır. Genlik ve güç spektrumları iki farklı özellik türüdür. Genlik ile ilgili özellikler genellikle zaman alanı serilerinden çıkarılırken güç spektrumu özellikleri genellikle frekans alanı analizlerinden çıkarılır. Ayrıca, dalgacık analizi adı verilen daha gelişmiş bir yöntem de frekans-zaman bölgesinde özellik çıkarımında kullanılmaktadır. Dalgacık analizinde, dalgacık araçlarını kullanarak sinyal özellikleri zaman ölçekli bir alanda çıkarılır (Asghari Oskoei & Hu, 2007). Bu özellikleri, genellikle volt (V) veya milivolt (mV) kullanan genlik tabanlı özelliklerdir. EMG sinyali sıfır ortalamalı stokastik bir sinyaldir, böylece genlik zamanla değişen bir standart sapma (SS) olarak görülebilir. EMG sinyalinin genliği, aktif MB'lerinin sayısı ve ateşleme hızı ile orantılıdır. Bu sinyalin genliği cildin kalınlığı, elektrot koşulları ve konumları, tespit edilen kas koşulları ve donanım koşulları gibi birçok faktörden etkilenebilir. Genlik özelliklerinin kalitesini belirlemek için sinyal-gürültü oranı (SGO) kullanılır. SGO standart sapma üzerinden sinyalin ortalama değeri ile hesaplanır. Ortalama mutlak değer (OMD) ve Karekök Ortalama (KO) zaman alanında ölçülen en sık kullanılan iki özelliktir.

EMG işaretinin frekans bandı incelendiğinde, aktif MB'lerin ateşleme hızı EMG'deki düşük frekans bandını etkilerken, kas lifinden geçen aksiyon potansiyelinin yüksek frekans bandını etkilediği görülmektedir. Yapılan çalışmalar, kısa bir süre içinde (40 saniyeden uzun olmayan) düşük istemli kasılma sırasında (genellikle maksimum istemli kasılmanın %30'unun altında) frekans alanı özelliklerinin durağan olarak kabul edilebileceğini ve özellik olarak kullanılabileceklerini göstermektedir (Karlsson vd., 2000).

Frekans alanı özellikleri de yorgunluk tahmini gibi kas çalışmalarında yaygın olarak kullanılmaktadır (Kaya & Ergin, 2021).

1.6.1. Ortalama Mutlak Değer

Ortalama mutlak değer vektörü sinyalin her bir örneğinin mutlak değerlerinin ortalamasının alınmasıyla elde edilir ve matematiksel olarak,

$$\overline{X}_k = \frac{1}{L} \sum_{i=1}^L |x_i| \quad (1)$$

biçiminde hesaplanır.

1.6.2. Kök Ortalama

Kök Ortalama EMG sinyalinin ortalama gücünün karekökünü tanımlar. Bu değer elektrik sinyalini ölçmek için kullanılmıştır çünkü kasların kasılması sırasında MB'deki fizyolojik aktiviteyi yansıtır. Eşitlik 2'deki gibi ifade edilir.

$$RMS = \sqrt{\frac{1}{L} \sum_{i=1}^L (x_i)^2} \quad (2)$$

1.6.3. Sıfır Geçiş Noktası

Sıfır Geçiş Noktası (SGN) yöntemi, sinyalin x eksenini kaç kez kestiğini hesaplar. Gürültü etkisini azaltmak için eşik değeri kullanılabilir. Eşitlik 3'teki gibi ifade edilir.

$$\text{sgn}(-x_k * x_{k+1}) \text{ ve } (|x_k - x_{k+1}| \geq \text{eşik}) \quad (3)$$

1.6.4. Dalga Uzunluğu

Dalga Uzunluğu (DU) sinyal eğiminin değiştiği noktaların sayısını hesaplar ve gürültüleri filtrelemek için bir eşik değeri kullanır. Eğer 4, 5 ve 6 numaralı eşitliklerdeki koşullar sağlanıyorsa, eğim işareti bir arttırılır (Clancy vd., 2002).

$$x_k > x_{k-1} \text{ ve } x_k > x_{k+1} \text{ veya } x_k < x_{k-1} \text{ ve } x_k < x_{k+1} \quad (4)$$

$$\text{ve } |x_k - x_{k-1}| > \text{eşik} \quad (5)$$

$$\text{veya } |x_k - x_{k+1}| > \text{eşik} \quad (6)$$

1.6.5. Willison Genliği

Willison Genliği (WG) sinyalin ardışık örnekleri üzerinde yapılan analizde, iki örnek arasındaki gerilim farkı, belirli bir eşik değerini aştığında WG değeri bir arttırılır ve Eşitlik 7 ve 8'deki gibi ifade edilir.

$$WG = \sum_{i=1}^{L-1} f(|x_i - x_{i+1}| - t) \quad (7)$$

$$f(x) = \begin{cases} 1 & \text{eğer } x \geq \text{eşik} \\ 0 & \text{diğer durumlarda} \end{cases} \quad (8)$$

1.6.6. Eğim İşareti Değişimi

Eğim İşareti Değişimi (EİD) EMG sinyalinin frekans bilgisini temsil etmek için kullanılan bir başka yöntemdir. Ardışık üç segment arasında pozitif ve negatif eğim arasındaki değişimin sayısı ve EMG sinyalinin parazitlenmesini önlemek için eşik fonksiyonu ile gerçekleştirilir (Sharma vd., 2016). Eşitlik 9 ve 10'da verilen bağıntılar ile hesaplanır.

$$EİD = \sum_{n=2}^{N-1} [f[(x_n - x_{n+1}) * (x_n - x_{n-1})]] \quad (9)$$

$$f(x) = \begin{cases} 1 & \text{eğer } x \geq \text{eşik} \\ 0 & \text{diğer durumlarda} \end{cases} \quad (10)$$

İşaret değişimi eğimi eşitlik 9 ve 10'daki hesaplanır.

1.6.7. AR Katsayıları

EMG sinyali AR Katsayıları özelliğini kullanılarak durağan bir Gauss fonksiyonu olarak görülebilir. EMG sinyali Eşitlik 11'deki gibi gösterilebilir.

$$x_k = \sum_{i=1}^m AR \cdot x_{k-i} \quad m. AR \text{ modeli} \quad (11)$$

1.6.8. Dalgacık Dönüşümü

Dalgacık, genliği sıfırdan başlayan, artan ve daha sonra tekrar sıfıra düşen küçük dalga benzeri bir salınımdır (Seena & Yomas, 2014). Matematiksel bir araç olarak dalgacık, birçok farklı veri türünden bilgi çıkarmak için kullanılabilir. Dalgacık Dönüşümü (DD) teorisi sinyal işlemeye dayalıdır ve Fourier dönüşümü temelinden geliştirilmiştir. Sinyalin doğrusal çalışmasını ve temel fonksiyonunu (ana dalgacık) gerçekleştirir. Ana dalgacığın ölçeklendirilmesi ve kaydırılmasıyla bir dizi integral fonksiyonu oluşturulur ve Eşitlik 12 ve 13'teki gibi ifade edilir.

$$x_{\omega}(a, b) = \int_{-a}^a x(t) \psi\left(\frac{t-b}{a}\right) dT \quad (12)$$

Ana dalgacık bir 'a' faktörü ile ölçeklendirilir ve bir 'b' faktörü ile ötelenerek;

$$\psi_{ab}(T) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (13)$$

elde edilir.

1.6.9. Stockwell Dönüşümü

Stockwell Dönüşümü (SD) kısa zamanlı Fourier dönüşümü DD temel alınarak geliştirilmiş ve 1996 yılında Stockwell tarafından önerilmiştir (Stockwell vd., 1996). Zaman-frekans alanında sEMG sinyalini dönüştürmek için S-dönüşümü kullanıldığında, Gauss penceresinin genişletilmesi ve çevrilmesi, Fourier spektrumu ile doğrudan bir ilişkiyi korur. Gauss penceresi frekansa göre değişebildiği için S-dönüşümü belirli bir anda frekans bilgisini elde edebilir (X. Shi vd., 2021). Belirli bir frekanstaki sinyalin genlik bilgisi elde edilebilir ve daha sonra sEMG sinyalinin zaman-frekans alanı özellikleri çıkarılabilir.


$x(t)$ sinyalinin S dönüşüm formülü Eşitlik 14 ile şöyle ifade edilmektedir:

$$S(\tau, F) = \int_{-\infty}^{+\infty} x(t) \frac{|F|}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 F^2}{2}} e^{-i2\pi f t} dt \quad (14)$$

Burada τ ve f sırasıyla zaman ve frekansı temsil eder. Aynı zamanda i sanal birimdir ve τ Gauss pencere fonksiyonunun merkezidir.

1.7. Makine Öğrenmesi

Makine öğrenimi terimi, 1959 yılında Amerikalı IBM çalışanı ve bilgisayar oyunları ve yapay zeka (YZ) alanında öncü olan Arthur Samuel tarafından ortaya atıldı. Makine öğrenimi, bir bilgisayar programının insan müdahalesi olmadan öğrenebileceği ve yeni verilere uyum sağlayabileceği konseptine sahip bir YZ alanıdır (Kundu, 2021). Şekil 4'te YZ, makine öğrenmesi ve derin öğrenme arasındaki ilişki görülmektedir.



Şekil 4. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki

Makine öğrenimi yapay zekanın bir alt kümesidir. Teoride bakıldığında makineler verileri alır ve öğrenir. Dünya üzerindeki işletmeler için YZ son derece umut vericidir. Makine öğrenmesi sistemleri büyük veri kümelerinden konuşma tanıma, nesne tanıma çeviri ve birçok görev bakımından bilgi ve eğitimi hızlı bir şekilde uygulayabilir. Makine öğrenmesi bir sistemin kalıpları kendi başına öğrenmesine ve tahminlerde bulunmasına olanak tanır. Makine öğrenimi yöntemleri girdi ve çıktılara, problemin türüne, amaçladıkları hedefe göre ve kullanılan veri türüne göre farklılık gösterdiklerinden dolayı aşağıdaki gibi sınıflandırılırlar:

- Denetimli Öğrenme
- Denetimsiz Öğrenme
- Yarı Denetimli Öğrenme
- Pekiştirmeli Öğrenme

1.7.1. Denetimli Öğrenme

Denetimli öğrenme algoritmaları hem girdileri hem de istenilen çıktıları içeren bir veri kümesinin matematiksel modelini oluştururlar (Wang vd., 2020). Veri, eğitim verisi olarak bilinir ve bir dizi eğitim örneğinden oluşur. Her eğitim örneğinin bir veya daha fazla girdisi ve istenilen çıktısı, aynı zamanda denetim sinyali olarak bilinen bir değere sahiptir. Matematiksel modelde, her eğitim örneği bir dizi veya vektör tarafından temsil edilir, bazen bir özellik vektörü olarak adlandırılır ve eğitim verisi bir matris tarafından temsil edilir. Hedef fonksiyonun iteratif olarak optimize edilmesi yoluyla, denetimli öğrenme algoritmaları, yeni girdilerle ilişkilendirilen çıktıyı tahmin etmek için kullanılabilecek bir fonksiyon öğrenirler. Optimal bir fonksiyon, algoritmanın eğitim verisinin bir parçası olmayan girdiler için doğru çıktıyı belirlemesine izin verecektir. Zamanla çıktılarını veya tahminlerini doğruluğunu artıran bir algoritma, o görevi yerine getirmeyi öğrenmiş olarak adlandırılır. Denetimli makine öğrenimi algoritmaları sınıflandırma ve regresyon algoritmaları olarak gruplandırılabilir.

Sınıflandırma algoritmaları, çıktıların sınırlı bir değer kümesine indirgenmiş olduğu durumlarda kullanılır. Sınıflandırma problemlerinde, algoritma her bir örneği iki veya daha fazla farklı sınıf arasında etiketlemeye çalışır. En popüler sınıflandırma yöntemleri DVM, k-EYK, KA, Naive Bayes (NB) ve Yapay Sinir Ağı (YSA) gibi algoritmalarlardır.

Regresyon algoritmaları, çıktıların bir aralık içinde herhangi bir sayısal değere sahip olabileceği durumlarda kullanılır. Burada, algoritma her bir örneğe sayısal bir hedef döndürür.

1.7.2. Denetimsiz Öğrenme

Denetimsiz öğrenme algoritmaları sadece girdileri içeren bir veri kümesini alır ve verideki yapıyı tespit eder. Bu nedenle, algoritmalar etiketlenmemiş, sınıflandırılmamış veya kategorize edilmemiş test verilerinden öğrenirler. Denetimsiz öğrenme, yalnızca girdi verilerine sahiptir. Denetimsiz öğrenmede amaç, verideki altta yatan yapıyı veya dağılımı modelleyerek veri hakkında daha fazla bilgi edinmektir (Alloghani vd., 2020). Bu tür yöntemlere denetimsiz öğrenme yöntemleri denir çünkü yukarıdaki denetimli öğrenmede olduğu gibi doğru cevaplar yoktur ve bir öğretmen yoktur. Algoritmalar verideki ilginç yapıları keşfetmek ve sunmak için kendi başlarına hareket ederler. Denetimsiz öğrenme yöntemlerine, kümeleme ve ilişkilendirme yöntemleri örnek olarak verilebilir.

1.7.3. Yarı Denetimli Öğrenme

Yarı-denetimli öğrenme, etiketlenmiş eğitim verisi olmayan denetimsiz öğrenme ile tamamen etiketlenmiş eğitim verisiyle denetimli öğrenme arasında yer alır (Zeebaree vd., 2021). Bazı eğitim örneklerinde eğitim etiketleri eksiktir, ancak birçok makine öğrenimi araştırmacısı, etiketlenmemiş verinin, az miktarda etiketli veri ile kullanıldığında öğrenme doğruluğunda önemli bir iyileşme sağlayabileceğini bulmuştur.

1.7.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, öznelere bir ortamda belirli bir birikimli ödül kavramını maksimize etmek için nasıl hareket etmeleri gerektiği ile ilgilenen bir makine öğrenimi alanıdır (“Pekiştirmeli öğrenme”, 2024). Geniş kapsamı nedeniyle bu alan oyun teorisi, kontrol teorisi, işletme araştırması, bilgi teorisi, simülasyon tabanlı optimizasyon, çoklu ajan sistemleri, sürü zekâsı, istatistik ve genetik algoritmalar gibi birçok başka disiplinde incelenmektedir. Makine öğreniminde ortam genellikle bir Markov Karar Süreci (MKS) olarak temsil edilir (Xiang & Foo, 2021). Birçok pekiştirme öğrenme algoritması dinamik

programlama tekniklerinden yararlanır. Pekiştirmeli öğrenme algoritmaları MKS'nin tam matematiksel bir modeline dair bilgiye dayanmaz ve tam modellerin uygulanabilir olmadığı durumlarda kullanılır. Pekiştirmeli öğrenme algoritmaları otonom araçlarda veya bir insan rakibe karşı oyun oynamayı öğrenmede kullanılır.

1.8. Denetimli Öğrenmeye Genel Bir Bakış

Denetimli öğrenme, EMG sinyallerinin analizi ve yorumlanmasında güçlü bir araçtır. Etiketli veriler kullanılarak eğitilen modeller, kas aktiviteleri hakkında değerli bilgiler sunar ve çeşitli klinik uygulamalarda önemli faydalar sağlar. Gelişen makine öğrenmesi algoritmaları ve artan veri miktarı ile, denetimli öğrenmenin EMG sinyallerindeki kullanımı daha da yaygınlaşmakta ve derinleşmektedir. Bu, kas fonksiyonlarının daha iyi anlaşılmasına ve çeşitli nörolojik ve fizyolojik bozuklukların daha etkili bir şekilde teşhis ve tedavi edilmesine olanak tanır. Denetimli öğrenme algoritmaları sınıflandırma ve regresyon olmak üzere 2 grupta incelenebilir. Bu iki algoritma da çeşitli tiplere ayrılmaktadır. Yaygın kullanılan bazı denetimli öğrenme teknikleri aşağıda verilmiştir:


1.8.1. K-En Yakın Komşu

K-EYK basit, uygulanabilir ve sık kullanımı olan denetimli makine öğrenmesi algoritmasıdır. Bu sınıflandırma yöntemi diğer yöntemlere göre daha basit bir şekilde uygulanabilir ve daha az karmaşıklığa sahiptir. Bu yöntemde özellikler çok boyutlu uzayda temsil edilir. Sonradan eklenen yeni veriler ve eğitim verileri arasındaki uzaklık hesabı ile sınıflandırma temeline dayanır (Asghar vd., 2022). Uzaklık hesabı Öklid, Manhattan veya başka teknikler olabilir. Bu teknikler ile uzaklık hesabı Eşitlik 15 ve 16'da fonksiyonlar ile hesaplanabilir.

$$\text{Öklid Hesabı} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (15)$$

$$\text{Manhattan Hesabı} = \sum_{i=1}^k |x_i - y_i| \quad (16)$$


Şekil 5'te Öklid hesabına dayalı bir örnek gösterilmiştir. Yeni veri geldiğinde sınıflar arasındaki eğitim verileri ile arasındaki mesafe (K değeri) Öklid yöntemi ile hesaplanır ve en yakın komşu uzaklık değerine göre sınıf belirlenir.



Şekil 5. Öklid hesaplamasına göre k-EYK tekniği

1.8.2. Destek Vektör Makineleri


DVM ilk olarak eğitim modelleri ve karar sınırı arasındaki boşluğu maksimum yapacak bir eğitim algoritması şeklinde öne sürülmüştür (Boser vd., 1992). Şekil 6'da gösterildiği gibi veriler arasında boşluk olacak şekilde destek vektörleri belirlenir. Sonra sınıflar arasındaki maksimum boşlukların ortasında optimal hiper düzlem seçilir. Daha sonrasında alınacak olan yeni veri bu hiper düzleme göre sınıflandırılır. Bu sayede veriler doğrusal olarak birbirinden ayrılabilir. Destek vektörlerinin arasındaki boşluğun artması amaçlanır çünkü bu sayede sınıflandırma işlemi doğruluk oranı artmaktadır. Temsili bir DVM aşağıdaki Şekil 6'da gösterilmiştir.



Şekil 6. Temsili bir DVM örneği

1.8.3. Karar Ağaçları

Karar ağaçları, sınıflandırma ve tahmin için en etkili ve kullanışlı tekniklerden biridir. Bir KA, her iç düğümün bir özniteliğe ilişkin bir teste karşılık geldiği, her dalın bir testin sonucuna karşılık geldiği ve her yaprak düğümünün (terminal düğüm) bir sınıf etiketi taşıdığı akış diyagramı benzeri bir ağaç yapısıdır. Şekil 7’de bir karar ağacı yapısı gösterilmiştir.



Şekil 7. Karar ağacı örneği


KA anlaşılabilir kurallar üretebilir. Ayrıca çok fazla hesaplama gerektirmeden sınıflandırma yaparlar ve tahmin veya sınıflandırma için hangi alanların en önemli olduğunu net bir şekilde belirtirler. Bu olumlu özelliklere rağmen KA'yı eğitmek hesaplama açısından pahalı olabilir. Bir KA oluşturma süreci hesaplama açısından pahalıdır. Her düğümde en iyi bölünmeyi bulmadan önce her adayın bölme alanı sıralanmalıdır.

1.8.4. Navie Bayes

Navie Bayes (NB)sınıflandırma algoritması, veri kümesinde bulunan her bir eleman için bütün durumların olasılığını hesaplar ve olasılık değeri en yüksek olan veriye göre sınıflandırmayı gerçekleştirir. Çeşitli NB algoritmaları bulunmaktadır. Gaussian Navie Bayes sınıflandırması bu algoritmalarından biridir. Bu sınıflandırmada her sınıfla ilgili sürekli özellikler Gaussian dağılıma göre dağıtılır. Bu yöntem kullanılarak eğitim verisinden her sınıf için ortalama ve standart sapma değerleri tahmin edilir. Bu sayede dağılım özetlenir.

1.9. Topolojik Veri Analizi

TVA, çeşitli verileri matematiksel ve geometrik yaklaşımlarla inceleyen özellikle Homoloji ile ilgili teknikleri kullanan bir konudur. Geleneksel yöntemlerin dışına çıkarak veri setlerinin yapısını daha ayrıntılı olarak incelemeyi amaçlar. Veriler arasındaki ilişkileri analiz etmede nicel yaklaşımlarından daha ötesini sunar. Nokta bulutu, çizgeler ve resimler topolojik veri analizinde kullanılan veri türlerinden bazılarıdır. Bu tez kapsamında nokta bulutu verileri kullanılmıştır. TVA gerçek verileri nokta bulutu haline dönüştürerek bu noktalar arasındaki topolojik ilişkilerin irdelenmesi esasına dayanır. Büyük ve kompleks veri setlerinde bu yaklaşım veri setleri içerisindeki karmaşık durumların ve desenlerin ortaya çıkmasını sağlamaktadır. Şekil 8'de bir zaman serisi sinyalin nokta bulutuna dönüştürülmüş hali gösterilmektedir.



Şekil 8. Ham veriden nokta bulutu elde edilmesi

TVA nokta bulutu haline dönüştürülen verinin kaç parçadan oluştuğunu, parçaların içindeki delikleri ve boşlukları analiz ederek veriyi tanımaya çalışır. Bu işlemi gerçekleştirirken simplikal kompleks adı verilen yapıları kullanır. Simplikal komplekslerin tespit edilmesi dayanıklı homoloji teorisini ortaya çıkarmaktadır. Dayanıklı Homoloji, var olan simplekslerin türlerine göre sayılarını çıkarma ve analiz edebilme işlemidir. Başlangıçta oluşturulan nokta bulutu verisinin belirsiz şekiller oluşturduğu görülür. Daha sonra nokta bulutundan simplekslerin elde edilmesiyle anlamlı şekiller ortaya çıkar. Nokta bulutundan simplekslerin ortaya çıkarılması metoduna Vietoris-Rips kompleksleri adı verilmektedir (Obayashi vd., 2022).

TVA kullanılarak verilerin analiz edilmesinin farklı avantajları mevcuttur. Birçok veri türünde uzaklık kavramı net olmamakla birlikte koordinat sistemleri doğal değildir ve koordinatlar arası ilişkiler anlamlı olmayabilmektedir. Aynı zamanda sayısal çıkarımların yanında niteleyici çıkarımlar daha kullanışlı olabilmektedir. TVA verinin tümüne koordinatlardan bağımsız bakarak topolojik açıdan ne kadar basit veya kompleks olduğunu anlamak, sayısal olarak fark edilemeyen özelliklerini ortaya çıkarmak için oldukça kullanışlı bir tekniktir.

1.9.1. Makine Öğrenmesinde Topolojik Veri Analizi

TVA teknikleri, makine öğrenmesi algoritmalarının performansını daha ileriye taşımak için umut vaat eden yaklaşımlar sunmaktadır. Makine öğrenmesi algoritmalarında kullanılan özellikler, TVA'da daha basit ve hızlı bir şekilde ortaya konulabilmektedir.

TVA’da kullanılan yöntemler geleneksel makine öğrenmesi yöntemlerine göre verilerdeki elde edilmesi zor olan özellikler daha kolay bir biçimde çıkarabilmektedir.

Makine öğrenmesi ile sinyal işleme analizinde klasik olarak çıkarılan özellikler, günümüzde veri analizinde yaygın olarak kullanılan araçlardır. Ancak bu özellikler, veri setlerinin içsel yapısını tam olarak yakalayamayabilir veya karmaşık ilişkileri ortaya çıkaramayabilir. Bu noktada, topolojik veri analizi ile elde edilebilecek olan bazı özellikler ile makine öğrenmesi algoritmaları birlikte kullanıldığında, veri setlerinin daha derin ve kapsamlı bir şekilde analiz edilmesini sağlanabilir. Özellikle topolojik veri analizinde, veri setlerindeki desenleri ve yapıları ortaya çıkarırken, makine öğrenmesi teknikleri bu yapıları modellemek ve analiz etmek için kullanılabilir. Bu, veri setlerindeki gizli ilişkileri keşfetmemize ve daha doğru tahminler yapmamıza olanak tanır.

Topolojik veri analizi aynı zamanda boyut azaltma ve özellik mühendisliği gibi diğer makine öğrenmesi teknikleriyle de entegre edilebilir. Bu, veri setlerinin daha iyi anlaşılmasını sağlar ve makine öğrenmesi modellerinin daha etkili bir şekilde çalışmasına katkıda bulunur.

Sonuç olarak, makine öğrenmesi ile topolojik veri analizi arasındaki ilişki, veri setlerinin daha derinlemesine analiz edilmesini ve karmaşık ilişkilerin keşfedilmesini sağlar. Bu, daha doğru ve güvenilir tahminler yapmak ve veri odaklı kararlar almak için önemli bir araçtır.

1.9.2. Simplikal Kompleks

Topolojide, simplikal komplekslerin kullanımı, karmaşık yapıların anlaşılmasını ve analizini kolaylaştırır. Basit geometrik nesnelerin birleşimiyle oluşturulan bu yapılar, topolojik özellikleri anlamak için güçlü bir araçtır ve matematiksel modellemelerden bilgisayar grafiklerine kadar geniş bir uygulama alanına sahiptir.


Simplikal komplekslerin temelini simpleks adı verilen yapılardan oluşurlar. Bir simpleks, köşeleri arasındaki kenarlarla ve kenarları arasındaki yüzeylerle tanımlanan bir geometrik nesnedir.

Bir simpleks, bir üçgen veya dört yüzlü kavramının genelleştirilmiş halidir ve rastgele boyutlara sahiptir (Leykam & Angelakis, 2023). Bir 0-simpleks bir noktadır, bir 1-simpleks bir kenardır ve bir 2-simpleks bir üçgendir. Bir k simpleks (S_k), $k + 1$ bağımsız noktanın ($u_0, u_1, \dots, u_k \in R^k$ konveks zarfıdır ve Eşitlik 17’deki ifade edilir.

$$S_k = \{ \theta_0 u_0 + \dots + \theta_k u_k \mid \sum_{i=0}^k \theta_i = 1, \theta_i \geq 0 \text{ for } i = 0, \dots, k \} \quad (17)$$

K bir simplikal kompleks olsun. K iki koşulu sağlamalıdır. Birincisi, K simplikal kompleksin her yüzü K içerisinde bulunmalıdır. Diğer koşul ise, K 'nın herhangi iki simpleksi, örneğin S_1 ve S_2 'nin boş olmayan kesişimi, ortak bir yüzeydir.

Simplekslerin birleşimi olan simplikal kompleksler, topolojik yapıların modellemesinde kullanılır ve homolojik cebir gibi alanlarda önemli bir rol oynar. Şekil 9'daki yapı incelendiğinde 0 simpleksin düğüme, 1 simpleksin kenara, 2 simpleksin üçgene ve 4 simpleksin bir dört yüzlüye karşılık geldiği görülmektedir.




Şekil 9. Simpleks yapıları

1.9.3. Betti Sayıları

Betti sayıları, topolojik veri analizi, görüntü işleme, makine öğrenimi ve diğer birçok alanda kullanılır. Özellikle veri setlerinin topolojik özelliklerinin anlaşılmasında ve karşılaştırılmasında önemli bir rol oynarlar. Betti sayıları, bir veri setindeki deliklerin veya boşlukların sayısını belirleyerek veri setinin yapısal karmaşıklığını ölçmek için kullanılır. Betti sayıları, topolojik yapıların anlaşılmasında ve analizinde önemli bir araçtır. Bir uzayın Betti sayılarının hesaplanması o uzayın karmaşıklığını ve yapısal özelliklerini daha iyi anlamamıza yardımcı olur.

Betti sayıları bir topolojik uzayın homoloji gruplarındaki boyutlarına dayanır ve topolojik yapıların karmaşıklığını ölçmek için kullanılan önemli bir matematiksel

kavramdır. Bir topolojik uzayın homoloji grupları o uzayın belirli boyutlardaki deliklerinin veya boşluklarının cebirsel özetlemesidir. Bir topolojik uzayın Betti sayıları (β) o uzayın belirli boyutlardaki “deliklerin” sayısını ve dolayısıyla homoloji gruplarının boyutlarını ifade eder. Şekil 10’da gösterildiği gibi 0.boyut betti sayısı bir uzaydaki bağıl bileşenlerin sayısını belirler. Örneğin, bir halka, bir veya birden fazla bileşene sahiptir, bu nedenle β_0 sayısı 1 veya daha büyük olacaktır. 1. boyut betti sayıları halka veya döngülerin sayısını belirler. Örneğin, bir daire β_1 sayısı 1’dir, çünkü bir döngü içerir. Ancak bir delikli bir donutun β_1 sayısı 2’dir çünkü iç ve dış döngüler vardır. 2. boyut betti sayıları bir uzaydaki boşlukların sayısını belirler. Örneğin bir küre β_2 sayısı 0’dır çünkü herhangi bir boşluk yoktur. Ancak bir torusun β_2 sayısı 1’dir çünkü içi ve dışı birbirinden ayıran bir boşluk vardır. Şekil 10’da bir simplikal kompleksin Betti sayıları verilmiştir.



$$\beta_0 = \text{Parça Sayısı} = 3$$

$$\beta_1 = \text{Delik (Çember) Sayısı} = 1$$

$$\beta_2 = \text{Boşluk Sayısı} = 1$$

Şekil 10. Betti sayıları

1.9.4. Kalıcı Homoloji


Kalıcı Homoloji topolojik veri analizinde kullanılan bir tekniktir ve veri setlerindeki topolojik özellikleri tanımlamak için kullanılır. Kalıcı Homoloji ile, simplikal komplekslerin

homolojik özellikleri incelenebilir ve bu özelliklerin değişimleri çeşitli ölçeklerde analiz edilebilir (Ravishanker & Chen, 2021).


Nokta bulutlarından topolojik yapıların çıkarılması, veri analizinde yaygın olarak kullanılan önemli bir tekniktir. Bu işlem için Vietoris-Rips kompleksi adı verilen bir dönüşüm metodolojisi sıklıkla tercih edilir ve nokta bulutundaki topolojik özellikleri çıkarmak için yaygın olarak kullanılır. Vietoris-Rips kompleksinde her bir noktanın diğer noktalara olan mesafesi kontrol edilerek, belirli bir mesafe eşiği içinde kalan noktalar arasında kenarlar oluşturarak Rips Kompleksi'nin 1-simpleksi oluşturulur.

Kalıcı homolojide veri setindeki her nokta 0-simpleks olarak kabul edilir. Yani başlangıçta her veri noktası bir simpleks olarak düşünülür. Şekil 11 a'da gözlemlenen 10 nokta bulutu, her bir veri noktasının etrafına belirli bir ölçek değerinde (filtrasyon değeri) daireler çizilerek temsil edilir. Bu, veri setine uzaktan bakma anlamına gelir. Daha sonra Şekil 11 b'de bu dairelerin çizildiği ölçek değeri artırılarak noktaların etrafındaki daireler büyütülür. Bu aşamada bazı dairelerin iç içe geçtiği ve tek bir yapı oluşturduğu gözlemlenir. Başlangıçtaki 10 ayrı parça bulunurken bu aşamada azalmıştır çünkü bazı noktalar birleşmiş veya bazı noktaların yok olduğu gözlemlenir. Şekil 11 c'ye bakıldığında ölçek değeri daha da arttırıldığında dairelerin birleşerek tek bir yapı haline geldiği görülür. Bu noktada bütün parçaların yok olduğu ve sadece tek bir parçanın hayatta kaldığı kabul edilir. Ancak ölçek değeri arttıkça yeni çemberlerin ve yapıların oluştuğu gözlemlenir. Bu yeni çemberler başlangıçta var olmayabilir, ancak belirli bir ölçek değerinden sonra ortaya çıkabilir. D de ölçek değeri daha da arttırılmış ve bazı çemberlerin yok olduğu ve diğerlerinin hayatta kaldığı görülür. Son olarak Şekil 11 d'de ölçek değeri maksimuma çıkarıldığında tüm çemberlerin yok olduğu ve veri setinin tek bir yapıya indirgendiği görülür.

Bu aşamalarda, başlangıçtaki verilerin birbirleriyle olan mesafeleri dikkate alınarak hangi ölçekte ve hangi yapıların oluştuğu belirlenir. Bu işlem, veri setindeki önemli desenlerin ve yapıların tespit edilmesine yardımcı olur ve dayanıklı homoloji olarak adlandırılır.




(a)



(b)


Şekil 11. Nokta bulutundan dayanaklı homoloji oluşumunun gösterimi (a) veri setinin nokta bulutu şeklindeki gösterimi, (b) ölçek değeri a iken homoloji gösterimi, (c) ölçek değeri b iken homoloji gösterimi, (d) ölçek değeri c iken homoloji gösterimi

Şekil 11' in devamı



Ölçek Değeri

(c)



Ölçek Değeri


(d)

1.9.5. Barkod ve Kalıcılık Diyagramları

Barkod ve kalıcılık diyagramları topolojik veri analizinde kullanılan iki önemli araçtır. Barkodlar veri setlerinin topolojik özelliklerini farklı ölçeklerde analiz edilmesini sağlar.

Ölçeklerin zaman içerisindeki değişimi elde edilen topolojik özelliklerin daha iyi kavramak anlamında etkilidir. Özelliklerin ortaya çıkma ve yok olma zamanlarını gösteren çizgiler her bir özelliğin yaşını temsil eder ve bu çizgiler barkod olarak adlandırılır.

Bir özelliğin doğum zamanı (ortaya çıkma) ve ölüm zamanı (yok olma) arasındaki fark, özelliğin yaşam süresini belirtir. Burada bahsedilen süre ölçek yani filtrasyon değerine karşılık gelmektedir. Şekil 10'da kalıcılık homolojisi gösterilen verinin Şekil 12'de barkod ve kalıcılık diyagramları gösterilmiştir. Barkod diyagramına bakıldığında 0. ölçekte veri setinin başlangıç durumunda meydana gelen tüm özelliklerin doğum anları belirgin şekilde görülebilir. Şekil 11'de b ölçeğinde iki çember deseni görülmektedir. Barkod diyagramında daha sonra ortaya çıkan bu desenlerin doğum ve ölüm anları farklı renklerle vurgulanmıştır. Bu sayede veri setinde meydana gelen tüm özelliklerin doğum ve ölüm anları belirlenebilir. Bu, veri setinin topolojik özelliklerinin ayrıntılı bir şekilde incelenmesine ve anlaşılmasına yardımcı olur.



Şekil 12. Barkod ve kalıcılık diyagramları

Kalıcılık diyagramları da kalıcılık homolojisi analizinde kullanılan bir araçtır. Barkodlar gibi veri setlerindeki topolojik özellikleri görselleştirmeye yardımcı olur. Ancak, kalıcılık diyagramları barkodlardan farklı bir görselleştirme şeklidir. Kalıcılık diyagramları, her bir topolojik özelliğin doğum ve ölüm zamanlarını gösteren bir nokta bulutu olarak düşünülebilir. Bu noktalar, doğum ve ölüm zamanlarını x ve y eksenlerinde gösterir. Her bir nokta, bir özelliğin yaşam süresini temsil eder. Bu diyagramlar veri setindeki topolojik değişiklikleri daha net bir şekilde görselleştirmek için kullanılır. Şekil 11'de sunulan kalıcılık homolojisi verisine dayanarak, Şekil 12'de kalıcılık diyagramı çizilmiştir. Kalıcılık

diyagramı incelendiğinde, tüm verilerin $y=x$ doğrusu üzerinde yer aldığı gözlemlenmektedir. Bu durumun nedeni, tüm verilerin ölüm zamanlarının doğum zamanlarından daha büyük olması gerektiğidir. Bu, topolojik değişikliklerin doğru şekilde temsil edilmesini sağlar ve veri setinin kalıcılık özelliklerinin açıkça anlaşılmasına katkıda bulunur. Kalıcılık diyagramları, veri setindeki topolojik değişiklikleri daha detaylı ve sezgisel bir şekilde anlamamıza yardımcı olur. Bu da veri setinin yapısını daha iyi anlamamızı ve modellememizi sağlar.

1.9.6. Topolojide Mesafe Ölçümü

Topolojik veri analizinde mesafe ölçümleri, veri setlerindeki yapıları ve ilişkileri anlamak için temel bir araçtır. Bu mesafe ölçümleri, veri noktaları arasındaki benzerlikleri ve farklılıkları ortaya çıkararak veri setlerindeki önemli desenleri ve yapıları belirlemeye yardımcı olur. Bu sayede, veri bilimcileri ve araştırmacılar, karmaşık veri kümelerinde gizlenmiş bilgileri keşfetmek ve daha derin anlayışlar elde etmek için güçlü bir araç setine sahip olurlar.

Darboğaz (bottleneck) mesafesi topolojik veri analizinde sıkça kullanılan mesafe ölçüm yöntemlerinden biridir. Darboğaz mesafesi, iki farklı kalıcılık diyagramı arasındaki en büyük yapısal farkı ölçer. İki diyagram arasındaki eşleştirilmiş noktalar arasındaki en büyük mesafe olarak tanımlanır. Bu mesafe ölçüsü, kalıcılık diyagramları arasındaki benzerlik veya farklılık hakkında bilgi sağlar ve veri kümesindeki topolojik değişiklikleri karşılaştırmak için kullanılır (Bastian Grossenbacher-Rieck, 2020).

İki kalıcılık diyagramı D ve D' olacak şekilde Bottlenecek mesafesi Eşitlik 18'deki gibi tanımlanır.

$$W_{\infty}(D, D') = \inf_{n: D \rightarrow D'} \sup \|x - n(x)\|_{\infty} \quad (18)$$

Korelasyon, sinyal işleme algoritmalarının performansını değerlendirmede ve gürültü giderme, örüntü tanıma gibi işlemlerde kullanılan bir yöntemdir. Korelasyonun ana amacı, iki veya daha fazla değişken arasındaki ilişkinin gücünü ve yönünü ifade eden istatistiksel bir ölçüdür ve TVA içi oldukça önemlidir. TVA'da korelasyonun yeri, veri setindeki topolojik desenlerin ve yapıların belirlenmesinde önemli bir rol oynar. Özellikle sinyal

işleme bağlamında, verilerin nokta bulutu temsilleri kullanılarak bu veriler arasındaki korelasyonlar, topolojik özellikler ve bağlantılar aracılığıyla analiz edilebilir.

Kovaryans ise değişkenler arasındaki ilişkiyi incelemek amacıyla kullanılan bir diğer matematiksel bağıntıdır. X ve Y farklı iki değişken olmak üzere kovaryans (X, Y) Eşitlik 19'deki gibi hesaplanır.

$$Kovaryans(X, Y) = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{N - 1} \quad (19)$$

x_i = X verisinin değeri

y_i = Y verisinin değeri

$\bar{x}$ = X 'in ortalama değeri

$\bar{y}$ = Y 'nin ortalama değeri

N = Veri sayısı

Korelasyon kovaryansın tahmini ölçüsü olarak düşünülebilir. Kovaryans ve korelasyon arasındaki ilişki Eşitlik 20'de gösterilmiştir.

$$Korelasyon = \rho(X, Y) = Kovaryans(X, Y) / \sigma_X \sigma_Y \quad (20)$$

Burada σ_X ve σ_Y sırasıyla X ve Y 'nin standart sapmasıdır.

1.10. Derin Öğrenme v


Derin öğrenme, veri setlerinden anlamlı özelliklerin çıkarılmasını ve ardından sınıflandırma, tespit veya segmentasyon gibi görevlerin gerçekleştirilmesinde kullanılır. Derin öğrenme modelleri ile büyük miktarda veri işlenebilir ve karmaşık yapılar öğrenilebilir.

Topolojik veri analizi ve derin öğrenme, farklı perspektiflerden karmaşık veri kümelerini analiz edebilmektedirler. Topolojik veri analizi, veri kümelerindeki yapısal özellikleri tanımlamak için kullanılırken, derin öğrenme, veri setlerinden anlamlı özelliklerin çıkarılmasını ve desenlerin öğrenilmesini sağlar. Bu nedenle, bu iki alan arasındaki ilişki, veri analizi ve keşfi için güçlü bir kombinasyon sunar. Örneğin, topolojik veri analizi, veri kümelerindeki önemli yapılar belirlenebilir ve bu yapıları temsil etmek için

uygun özelliklerin seçilmesini sağlayabilir. Ardından, derin öğrenme, bu özellikler üzerinde daha fazla işlem yaparak sınıflandırma veya tespit gibi görevleri gerçekleştirebilir. Bu kombinasyon, karmaşık veri kümelerindeki derin yapıları anlama ve çeşitli görevleri gerçekleştirme yeteneğini sağlayacaktır.


1.10.1. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA), girdi verisi olarak görüntüleri kullanan bir derin öğrenme algoritmasıdır. Görüntülerin özelliklerini kullanarak görüntüleri birbirinden ayırt etmektedir diğer bir deyişle sınıflandırma işlemini gerçekleştirmektedir (Zafar vd., 2022). ESA’da kullanılacak veriler için gerekli olan ön işleme, diğer sınıflandırma algoritmalarına kıyasla çok daha düşüktür. Bunun sebebi ise ESA’nın diğer sınıflandırma algoritmalarından farklı olarak filtreleri öğrenme yeteneğine sahiptir. Bir ESA modeli Şekil 13’te gösterilmiştir. ESA mimarisi temel olarak üç katmandan oluşur. Evrişimli Katman (Convolutional Layer), Ortaklama Katmanı (Pooling Layer) ve Tam Bağlantılı Katman (Fully Connected Layer). Bu katmanlardan geçen görsel, farklı işlemlerden geçirilerek derin öğrenme modeline girecek hale gelir.



Şekil 13. Evrişimsel sinir ağı

Şekil 14’teki gibi evrişimli katmanda filtreler görev alır. Burada Kernel (2x2) filtresi kullanılmıştır. Filtre giriş görüntüsü üzerinde kaydırılarak görüntü matrisindeki değerler ile çarpılıp toplanır.




Şekil 14. Evrişimsel katman

Ortaklama katmanı, tipik olarak bir miktar uzamsal değişkenlik gösteren bir evrişim katmanından sonra gelen bir örnekleme yöntemidir. Özellikle, maksimum ve ortalama ortaklama, sırasıyla maksimum ve ortalama değer alınacağı özel ortaklama türleridir.



Şekil 15. Havuzlama katmanı

Şekil 15'te yapılan her ortaklama işlemi geçerli matrisin maksimum değerini seçer. Algılanan özellikleri korur ve en sık kullanılan ortaklama yöntemidir.



Şekil 16. Tam bağlantılı katman


ESA'nın son adımı tam bağlantılı katmanda gerçekleşir. Şekil 16'da gösterildiği üzere tam bağlantı katmanları, mimarinin bir katmandaki bütün düğüm ve nöronlarının bir sonraki katmanlara bağlandığı bir YSA türüdür. Bu ağ türü hesaplama açısından karmaşık olmasının yanı sıra aşırı yüklenmeye meyillidir. Elde edilen verilere uygulanan düzleştirme (flattening) işleminden sonra sinir ağları ile öğrenme işlemi uygulanır.

1.10.2. Derin Öğrenme Modelleri

Derin öğrenme modelleri, karmaşık veri yapılarını modellemek ve öğrenmek için yapay sinir ağlarından faydalanmaktadırlar. Bu modeller, çok katmanlı mimarileri büyük miktarda veri ile besleyerek karmaşık ilişkileri ve desenleri öğrenebilmektedirler. Modeller, ESA, Tam Bağlantılı Sinir Ağı (DNN) veya her ikisini de içerebilecek karmaşık yapılarla tasarlanabilirler. Evrişimli katmanlar genellikle görsel veri analizi için kullanılırken, tam bağlantılı katmanlar daha genel yapıları modellemek için kullanılır. Aktivasyon fonksiyonu olarak Sigmoid, ReLU (Rectified Linear Unit) ve Tanh gibi yaygın aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları, sinir ağlarının katmanları arasındaki non-lineer ilişkileri yakalamak için kullanılır. Ayrıca derin öğrenme modelleri, genel özellikleri öğrendikleri için farklı görevlerde transfer öğrenme için de kullanılabilirler. Optimizasyon algoritmaları ve geri yayılım, derin öğrenme modellerinin eğitiminde yaygın olarak

kullanılan tekniklerdir. Bu tez çalışması kapsamında kullanılan derin öğrenme modelleri aşağıda açıklanmıştır.

EfficientNetB0 ve EfficientNetB4: EfficientNet, Google Brain tarafından geliştirilen ve derin öğrenme alanında önemli bir gelişme olan bir dizi derin öğrenme modelidir. Bu modeller, hesaplama ve parametre açısından daha verimli olacak şekilde özel olarak tasarlanmıştır. Bu nedenle, diğer derin öğrenme modellerine kıyasla daha hafif ve daha etkilidirler.




Şekil 17. Özellik çıkarımı EfficientNet Katmanları

EfficientNet, temelde bir ölçekleme stratejisi kullanır. Bu strateji, ağıın genişliğini, derinliğini ve çözünürlüğünü dengeli bir şekilde ölçeklemek için bir dizi ölçekleme katsayısı kullanır. Bu sayede, ağıın her bir bileşeni, verimli bir şekilde optimize edilir ve elde edilen model, daha az parametreyle daha iyi performans sağlar (Arivalagan vd., 2024). EfficientNetB0, bu serinin en temel modelidir. Daha sonra, EfficientNetB1, EfficientNetB2 vb. gibi daha büyük ve daha karmaşık modeller gelir. Her bir model, öncekinden daha büyük bir ölçekleme katsayısıyla genişletilir, böylece daha fazla parametreye ve hesaplama gücüne

sahip olur. EfficientNetB4, EfficientNet serisinin daha büyük ve daha karmaşık bir modelidir (Bhardwaj vd., 2023). Derinlik, genişlik ve çözünürlüğü daha fazladır ve daha büyük veri kümeleri veya daha karmaşık görevler için uygun olabilir. EfficientNetB4, diğer EfficientNet modelleri gibi, hesaplama ve parametre açısından daha verimli olacak şekilde tasarlanmıştır. Şekil 17 ve Şekil 18’de derin öğrenme modellerinin çalışma kapsamında kullanılan katmanları gösterilmiştir.

VGG16: VGG19, Oxford Üniversitesi'nden bir grup araştırmacı tarafından geliştirilen ve 2014 yılında tanıtılan bir derin öğrenme modelidir. Resmi adı Oxford Visual Geometry Group (VGG) tarafından geliştirilen 19 katmanlı ESA modelidir.




Şekil 18. Özellik çıkarımı için VGG19 katmanları

VGG19 modeli, 16 katmanlı VGG16 modeline benzer, ancak daha fazla evrişim ve tam bağlantılı katman içerir. VGG19'un mimarisi, ardışık evrişim katmanlarından ve ardından tam bağlantılı katmanlardan oluşur (Sisodia vd., 2023). Her evrişim katmanı ardışık olarak 3x3 boyutunda filtrelerle evrişim işlemini gerçekleştirir, ardından ReLU aktivasyon fonksiyonu ve bir MaxPooling katmanı uygulanır. Bu yapı, küçük boyutlu filtrelerin derinlik

arttıkça daha etkili olduğunu gösteren bir yaklaşımdır. VGG19 modelinin temel özelliklerinden biri, basit ve tekrarlanabilir bir yapıya sahip olmasıdır (Goceri, 2023). Bu, modelin kolayca anlaşılabilir ve uygulanabilir olmasını sağlar. Ayrıca, VGG19 modeli, birçok görsel görevde başarılı sonuçlar elde etmiştir.

1.10.3. Kapsül Ağı (CapsNet)

Kapsül ağı (CapsNet), Geoffrey Hinton ve ekibi tarafından 2017 yılında önerilen bir derin öğrenme mimarisidir (Taylor vd., 2010). Kapsül ağı, geleneksel ESA mimarisine alternatif olarak önerilmiştir ve özellikle görüntü işleme görevlerindeki başarısızlıkları ele almayı hedefler. Kapsül ağının temel özelliği, nesne tanıma ve diğer görsel görevlerdeki eksiklikleri düzeltmek için kapsüller adı verilen yeni birimleri kullanmasıdır (R. Shi & Niu, 2020). Kapsüller, geleneksel sinir hücrelerinden farklı olarak, sadece özniteliklerin varlığına değil, aynı zamanda özelliklerin yönüne, boyutuna, deformasyonu gibi başka özelliklerine de duyarlıdır. Kapsül ağı, kapsüller arasındaki ilişkileri modellemek için dinamik maruz bırakma algoritmasını kullanır. Şekil 19'da kapsül ağı modeli verilmiştir. Bu algoritma, kapsüllerin birbirleriyle etkileşimini ve dolayısıyla daha karmaşık özellik yapılarını daha iyi öğrenmesini sağlar. Ayrıca, kapsül ağının daha genel birleştirme özellikleri vardır, bu da daha güçlü ve daha stabil özelliklerin çıkarılmasına yardımcı olur. Kapsül ağı özellikle nesne tanıma, görüntü sınıflandırma ve segmentasyon gibi görsel işleme görevlerinde kullanılmak üzere tasarlanmıştır. Ancak, henüz geleneksel ESA'lara kıyasla geniş çapta benimsenmemiştir ve üzerinde çalışılması gereken birçok alan bulunmaktadır.



Şekil 19. Kapsül Ağı

2. YAPILAN ÇALIŞMALAR

Bu tez çalışması kapsamında EMG sinyalleri üç farklı yaklaşım altında incelenmiş ve sonuçları karşılaştırılmıştır. İlk araştırma, geleneksel makine öğrenmesi algoritmaları kullanılarak sensör seçiminin sınıflandırma üzerine etkisi incelenmiştir. İkinci çalışmada ise topolojik veri analizi uygulamalarından yararlanılarak özellik çıkarılmış ve sınıflandırma yapılmıştır. Son olarak üçüncü çalışmada ise derin öğrenme modelleri kullanılarak TVA ile çıkarılan özellikler görüntü haline dönüştürülmüş ve EMG sinyallerinin işlenmesi gerçekleştirilmiştir. Bu bölümde, yapılan her üç çalışma ve elde edilen sonuçlar ayrıntılı bir şekilde incelenmiştir.

2.1. Makine Öğrenmesi Algoritmaları ile EMG Sinyal İşleme

İlk çalışmada EMG sinyalleri, makine öğrenmesi algoritmalarıyla işlenmiştir. Bu işlem için öncelikle EMG sinyallerine ön işlem uygulanmıştır. Ardından sinyaller pencereleme işlemine tabi tutularak, elektriksel aktivitenin en belirgin olduğu sensörlerin belirlenmesi için varyans hesaplamaları yapılmıştır. Son olarak seçilen sensörlerden özellik çıkarımı gerçekleştirilmiş ve farklı öznitelikler ve bunların kombinasyonları kullanılarak sınıflandırma işlemine geçilmiştir.

2.1.1. Veri Ön İşleme

Ön işleme, veri setinin analiz veya modelleme için uygun hale getirilmesini içeren adımların genel adıdır. Veri seti mat uzantılı dosyalarından yüklenir ve her bir dosyadaki verinin durumlarına göre verilerin boyutları ve genlikleri ayarlanarak, eksik değerler doldurularak veya filtrelenerek uygun hale getirilir. Bu ön işlem adımı, verinin analiz veya modelleme süreci öncesinde yapılır ve verinin doğruluğunu artırmak, anlamlı özelliklerin çıkarılmasını sağlamak veya model performansını iyileştirmek amacıyla gerçekleştirilir. Bu nedenle, veri işleme ve ön işleme adımları genellikle veri bilimi veya makine öğrenimi projelerinin temel bir parçasıdır.

Yapılan bu çalışmada veri uzunluğu 1000 olarak sınırlandırılmış olup z normalizasyon işlemi yapılmıştır. Z normalizasyonu, bir veri setindeki değerleri standartlaştırmak için kullanılan bir yöntemdir. Bu işlem, verilerin ortalamasını 0 ve standart sapmasını 1 olacak

şekilde dönüştürmeyi amaçlar. Z-normalizasyonu, özellikle verilerin farklı ölçeklerde olduğu durumlarda, karşılaştırma yapılmasını kolaylaştırır. Matematiksel olarak, bir veri noktasının z-normalize edilmiş değeri Eşitlik 21'deki gibi hesaplanır.

$$z = \frac{x - \mu}{\sigma} \quad (21)$$


μ = ortalama

σ = Standart sapma

Ayrıca her bir mat dosyası işlenip her dosya adından sınıf numarası çıkarılarak sınıf değişkeni oluşturulmuştur. Buradan sonuç olarak, 1000x128x560 boyutlarındaki tüm veriden 560 x (özellik sayısı x pencere sayısı) boyutunda özellik matrisi ve 560x1 boyutundan sınıf matrisleri elde edilmiştir. İfade edilen 1000 değeri veri uzunluğunu 128 kanal sayısını (sensör sayısı), 560 ise 8 farklı sınıftan 70'er örneği temsil etmektedir.

2.1.2. Pencereleme


Pencereleme, elektromiyografi sinyallerini işlerken kullanılan önemli bir veri işleme tekniğidir. Bu yöntem, veriyi daha anlamlı ve kullanışlı parçalara bölmek için kullanılır. Bu çalışmada, 1000*128*560 boyutundaki veriye uygulanan pencereleme işlemi, verinin ve kullanım esnekliğini önemli ölçüde arttırmıştır. Şekil 20'de gösterildiği gibi pencere boyutu 256 ve kaydıma değeri 64 seçilerek pencereleme işlemi, veri setinin boyutunu 256*128*6720'ye çıkarmıştır. Bu, her bir verinin özgün veriyi daha küçük ve yönetilebilir parçalara böldüğü anlamına gelir. Pencereleme tekniği ayrıca, sinyali herhangi bir pozisyon veya konumda kaydetmek için sensörlerin özel bir konumda olmasına ihtiyaç duymadan, sinyali analiz etme esnekliği sunar. Diğer bir katkısı ise sınıfların örnek sayısının artırmasını sağlar.



Şekil 20. Pencereleme yöntemi

2.1.3. Sensör Seçimi

CapgMyo veri seti 128 farklı sensör kullanılarak oluşturulmuştur. Kaslardaki elektriksel aktivite bilgisi her konumda aynı olmadığından dolayı sensörler de farklı elektriksel bilgiye sahiptir. Bazı sensörler yüksek elektriksel aktivite bilgisine sahipken bazı sensörler daha düşük elektriksel aktivite bilgisine sahiptir veya herhangi bir bilgi içermemektedir. Yapılan bu çalışmada sensör seçimi yapılarak makine öğrenme algoritmalarının yüksek başarıma sahip olmalarına çalışılmıştır. Bu kapsamda 128 sensör içerisinde varyans değerlendirmesi yapılarak sensör eliminasyonu gerçekleştirilmiştir. Burada varyans, sinyalin değişkenliğini ölçmek için kullanılan bir ölçüttür. Herhangi bir sensörden alınan EMG işaretinin varyansı o sensördeki elektriksel bilginin ne kadar değişken olduğunu bize göstermektedir.



Şekil 21. Tüm sensörlerin varyans değerleri

Varyans değerinin bir sensörde düşük olması, o sensördeki elektriksel aktivite değişkenliğinin sabit veya düşük değişkenlik seviyesine sahip olduğunu bize gösterir. Bu sebeple o sensörden elde edilecek sınıf bilgisinin tespiti daha az düşük başarımlı olabilmektedir. Varyansın yüksek olması ise o sensörde elektriksel aktivite bilgisinin daha yüksek seviyede ve daha değişken olduğunu bize gösterir. Buradan o sensörün ilişkili olduğu kas veya kas grubunun daha aktif bir bilgiye sahip olduğu anlaşılmaktadır.


Başlangıçta 128 sensörün varyans değerleri hesaplanmıştır. Şekil 21’de tüm sensörlerin varyans değerleri görülmektedir. Daha sonra kaç sensörün elenmesi gerektiğinin daha iyi analizi varyans değerleri küçükten büyüğe doğru sıralanmıştır. En düşük varyans değerine sahip 48 sensör ele alınmıştır ve incelenmiştir. Bu 48 sensörün varyans değerinin çok düşük değerlerde olduğu görülmektedir. Tablo 1’de bu sensörlerin varyans değerleri verilmiştir. Tabloda ayrıca varyans değeri en düşük 48 sensörün 128 sensör içerisinde hangi sırada bulunan sensörün olduğu da verilmiştir. Örneğin 4. sırada bulunan sensörün varyans değeri 0.0124 iken son sırada bulunan 128 numaralı sensörün varyans değeri 0.0051’dir.

Tablo 1. En düşük 40 sensörün sensör sırası ve varyans değeri

Sensör No	Varyans Değeri	Sensör No	Varyans Değeri
4	0.0124	104	0.0057
9	0.0010	105	0.0023
10	0.0009	106	0.0040
11	0.0014	107	0.0033
15	0.0156	108	0.0058
17	0.0010	109	0.0052
18	0.0132	110	0.0059
28	0.0011	111	0.0159
29	0.0010	113	0.0014
30	0.0011	114	0.0019
31	0.0141	115	0.0025
32	0.0098	116	0.0018
33	0.0157	117	0.0022
34	0.0126	118	0.0025
73	0.0107	119	0.0016
78	0.0016	120	0.0029
79	0.0016	121	0.0023
80	0.0154	122	0.0017
89	0.0139	123	0.0025
99	0.0149	124	0.0036
100	0.0011	125	0.0029
101	0.0009	126	0.0029
102	0.0015	127	0.0044
103	0.0107	128	0.0051

Sensör eliminasyonu yaklaşımı ile en düşük varyans değerine sahip sensörlerin elenmesi ile elektriksel aktivite ve sınıf bilgisi tespitinin daha yüksek başarımla elde edileceği düşünülmüştür. 48 sensör içerisinde varyans değeri düşük olmasına rağmen elektriksel aktivite bilgisi taşıyan sensörler olabilmektedir. Bu sebeple en düşük varyansa sahip 48 sensörün tamamının elenmesinin yanında en düşük varyansa sahip 28 ve 8 sensör de ayrı ayrı elemeye tabi tutulmuştur. Bu üç farklı durum için ayrı ayrı EMG sinyalleri sınıflandırılmış ve sonuçları ilerleyen kısımda paylaşılmıştır.

Şekil 22’de 128 sensörün elektriksel aktivite bilgisi farklı bir görüntü ile analiz edilmiştir. Burada yüzey EMG sensörleri dairesel bir grafik şeklinde çizilmiştir. İşlem hacmi yoğunluğundan dolayı sensörler 200 birimlik parçaya indirgenip çizdirilmiştir.



Şekil 22. Yüzey EMG sensörlerinin dairesel grafiği

Grafikte mavi ve kırmızı noktalar varyans değerinin diğer noktalara göre daha yüksek olduğu kısımları içermektedir. Siyah noktalar ise varyans değerinin diğer noktalara göre daha düşük olduğu kısımları içermektedir. Ayrıca Şekil 22’de gibi dairesel grafiği elde edilen sensör takımlarından hangi kas bölgelerinde daha yoğun elektriksel aktivite olduğu daha kolay bir şekilde anlaşılmaktadır.

2.1.4. Özellik Çıkarımı ve Sınıflandırma

Veri ön işleme, pencereleme ve sensör seçimi işlemleri sonucunda, EMG verileri özellik çıkarımı ve sınıflandırma işlemlerine yönelik olarak hazırlanmıştır. Bu aşamada, EMG verilerinden toplamda 13 farklı özellik çıkarımı gerçekleştirilmiştir. Aşağıda kullanılan özellikler belirtilmiştir.

Öznitelikler ve Kısaltmaları:

- Sıfır Geçiş Noktası (SGN)
- Eğim İşareti Değişimi (EİD)
- Karekök Ortalama (KO)
- Dalgaboyu (DB)
- Ortalama Mutlak Değer (OMD)
- AR Katsayıları (AR)
- S Dönüşümü (SD)
- Dalgacık Dönüşümü (DD)
- Sıfır Geçiş Alanı (SGA)
- Sıfır Geçiş Diferansiyeli (SGD)
- Sıfır Geçiş Diferansiye Konumlar (SGDK)
- Sıfır Geçiş Çoğaltılmış Diferansiyel Konumlar (SGÇDK)
- Willison Genliği (WG)

Yukarıda belirtilen öznitelikler arasında, sıfır geçiş özelliklerinin çeşitli türevleri kullanılmıştır. Sıfır geçiş noktaları özelliği, elektriksel aktivitedeki değişimleri yakalamada önemli bir rol oynar ve yapılan çalışmalar, bu özelliğin yüksek sınıflandırma performansı sağladığını göstermektedir. Bu nedenle, Sıfır Geçiş Alanı (SGA), Sıfır Geçiş Diferansiyeli (SGD), Sıfır Geçiş Diferansiyel Konumları (SGDK) ve Sıfır Geçiş Çoğaltılmış Diferansiyel Konumları (SGÇDK) gibi farklı sıfır geçiş noktası özellikleri türetilmiştir. Bu özellikler, sinyalin farklı yönlerini ve özelliklerini temsil ederek sınıflandırma doğruluğunu artırmaya yardımcı olmuştur. Yukarıda belirtilen öznitelikler kullanılarak EMG sinyalinin öznitelikleri çıkarılmıştır. K-EYK sınıflandırma algoritması kullanılarak, EMG verileri farklı özellik kombinasyonları elde edilerek sınıflandırılmıştır.

Bu çalışmada EMG sinyalini sınıflandırmada k-EYK algoritmasının kullanılmasının sebepleri; k-EYK algoritması oldukça basit ve anlaşılması kolaydır, EMG sinyalleri zaman serisi verileridir ve k-EYK, bu tür verilerde iyi performans gösterir, k-EYK 'nin k- değeri gibi tek bir parametresi vardır. Bu, modeli kullanırken değiştirilebilir ve farklı sonuçlar elde etmek için ayarlanabilir. Bu, EMG sinyallerini işlerken farklı parametre ayarlarını deneyerek en iyi performansı elde etmek için esneklik sağlar. EMG sinyallerinin genellikle yüksek

boyutlu özellik vektörleriyle temsil edildiği durumlarda, k-EYK gibi basit algoritmalar, ölçeklenebilirlik avantajları sunar. Büyük veri setlerinde bile etkili bir şekilde çalışabilirler.

Aynı zamanda sınıflandırıcıların doğruluğunu araştırmak için çapraz doğrulama (cross-validation) algoritması kullanılmıştır. Bu çalışmada 5-kat çapraz doğrulama algoritması kullanılmıştır. Bu yöntem ile veri seti 5 eşit parçaya bölünmüştür ve her bir parça sırayla test seti olarak kullanılır iken geri kalan parçalar eğitim seti olarak kullanılmıştır. Bu işlem 5 kez tekrarlanmıştır. Genel sınıflandırma başarımları denemeden elde edilen başarımların ortalaması alınarak bulunmuştur. Bu yöntemin seçilmesinin sebebi, modelin genelleme yeteneğini daha iyi değerlendirmektir çünkü veri seti farklı parçalara bölünerek modelin farklı veri kesitleri üzerinde test edilmesini sağlar. Bu, modelin gerçek dünya verilerine daha iyi uymasına ve daha iyi genelleme yapmasına yardımcı olmaktadır.

Bu kısmın devamında EMG sinyallerinin sınıflandırma başarımları oranları verilmiştir. Sonuçlar seçili tüm sensörler (128 Sensör), seçili 120 sensör ve seçili 80 sensör için ayrı ayrı verilmiştir. Aynı zamanda özelliklerin tek tek, ikili, üçlü ve dörtlü kombinasyonları ayrı ayrı verilerek sonuçlar kayıt altına alınmıştır.

Tablo 2. Seçili 80 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları

Özellikler	SGN	EİD	KO	DB	OMD	AR	SD	DD	SGA	SGD	SGDK	SGÇDK	WG
SGN	99.45	99.73	99.14	99.24	99.39	93.30	99.14	99.06	80.52	99.46	99.23	98.56	99.15
EİD	0.00	99.36	99.27	99.35	99.52	93.99	99.38	99.26	81.95	99.60	99.52	99.03	99.42
KO	0.00	0.00	98.54	98.57	98.54	93.05	98.54	97.60	80.09	99.18	99.18	96.40	98.56
DB	0.00	0.00	0.00	98.41	98.74	92.80	98.23	96.74	81.29	99.32	99.32	91.18	98.17
OMD	0.00	0.00	0.00	0.00	98.63	93.33	98.45	97.80	80.85	99.18	99.15	96.50	98.72
AR	0.00	0.00	0.00	0.00	0.00	91.99	93.90	92.08	87.65	94.30	94.49	92.08	93.48
SD	0.00	0.00	0.00	0.00	0.00	0.00	98.27	97.50	82.90	99.23	99.27	96.46	98.35
DD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	14.33	78.56	99.30	99.27	55.82	90.64
SGA	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	77.56	81.73	81.47	78.44	80.67
SGD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	99.40	99.20	99.03	99.36
SGDK	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	99.17	98.63	99.33
SGÇDK	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	51.43	84.82
WG	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	92.77

Tablo 2’deki sınıflandırma performansları seçili 80 sensör içindir. Tablo içerisinde her bir özelliğin kendisi ile kesişim değeri o özelliğin tek başına sınıflandırma başarımına etkisini göstermektedir. Bu değerler köşegen üzerindeki değerlerdir. Köşegen üzerindeki değerlerin haricindeki köşe dışı değerler özelliklerin ikili kombinasyonlarının sınıflandırma performanslarına etkileridir. Özelliklerin tek başına sergiledikleri performanslara bakıldığında en yüksek performansın sıfır geçiş özelliğinde olduğu görülmektedir. Tek başına en düşük performansı içeren özellik ise dalgacık dönüşümüdür. İkili en yüksek performansı ise sıfır geçiş ve eğim işareti değişimi özelliklerinin kombinasyonları göstermiştir. İkili en düşük performans dalgacık dönüşümü ve sıfır geçiş alanı özelliklerinin kombinasyonları göstermiştir. Tablo 3’te seçili 120 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları gösterilmiştir. Köşegen değerlerine bakıldığında özelliklerin tek başına kullanıldığında sınıflandırma performansları görülmektedir. En yüksek performans seçili 80 sensörde olduğu sıfır geçiş özelliğine aittir. En düşük değer olarak benzer performansı seçili 80 sensörde olduğu gibi dalgacık dönüşümü özelliği göstermektedir. En iyi ikili kombinasyon değeri seçili 80 sensörde olduğu gibi fakat daha yüksek bir değerde sıfır geçiş ve eğim işareti değişimi özelliklerinin kombinasyonlarına aittir. Genel olarak seçili 120 sensörde seçili 80 sensöre göre performansın arttığı gözlemlenmiştir.

Tablo 3. Seçili 120 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları

Özellikler	SGN	EİD	KO	DB	OMD	AR	SD	DD	SGA	SGD	SGDK	SGÇDK	WG
SGN	99.60	99.75	99.40	99.29	99.51	92.54	99.43	99.43	81.32	99.52	99.61	99.33	99.49
EİD	0.00	99.52	99.40	99.24	99.12	93.68	99.18	99.52	83.24	99.67	99.75	99.26	99.29
KO	0.00	0.00	98.65	98.68	98.59	92.19	98.38	97.66	82.44	99.51	99.48	97.28	98.29
DB	0.00	0.00	0.00	98.10	98.57	92.43	98.10	96.90	82.80	99.48	99.64	94.93	98.04
OMD	0.00	0.00	0.00	0.00	98.78	92.59	98.56	98.26	82.68	99.55	99.46	97.23	98.44
AR	0.00	0.00	0.00	0.00	0.00	91.07	93.36	91.10	87.04	94.46	94.39	91.03	92.74
SD	0.00	0.00	0.00	0.00	0.00	0.00	98.26	97.60	84.15	99.55	99.40	97.31	98.17
DD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	14.20	79.76	99.61	99.52	57.32	87.14
SGA	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	79.58	83.69	83.14	80.06	83.39
SGD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	99.57	99.49	99.55	99.51
SGDK	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	99.54	99.35	99.38
SGÇDK	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	51.43	88.18
WG	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	86.85

Tablo 4. Seçili 128 sensörde özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performansları

Özellikler	SGN	EİD	KO	DB	OMD	AR	SD	DD	SGA	SGD	SGDK	SGÇDK	WG
SGN	98.74	99.32	98.94	99.05	99.11	89.29	99.00	98.71	79.61	98.82	98.87	98.78	99.08
EİD	0.00	98.69	98.91	99.18	98.76	91.00	98.99	98.94	80.67	99.21	99.30	98.79	99.12
KO	0.00	0.00	98.05	98.36	98.08	89.43	97.92	97.16	80.48	98.84	98.69	96.79	97.72
DB	0.00	0.00	0.00	97.57	98.17	89.81	97.75	96.49	81.21	99.12	98.81	94.64	97.32
OMD	0.00	0.00	0.00	0.00	97.84	89.61	98.26	97.54	80.88	98.97	98.66	96.83	98.02
AR	0.00	0.00	0.00	0.00	0.00	87.53	90.58	87.38	84.38	91.90	92.65	87.87	89.64
SD	0.00	0.00	0.00	0.00	0.00	0.00	97.54	97.07	82.90	99.12	98.82	97.11	97.46
DD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	15.34	77.65	98.90	98.59	57.23	86.64
SGA	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	77.65	80.79	80.80	77.83	81.56
SGD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	98.85	98.82	98.47	98.88
SGDK	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	98.48	98.27	98.75
SGÇDK	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	52.84	88.57
WG	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	86.41

Tablo 4, tüm sensörler aktif halde iken özelliklerin tekli ve ikili kombinasyonlarının sınıflandırma performanslarına etkisi görülmektedir. Bu durum verinin sensörlerinin ham hali olarak düşünülebilir. Bu duruma bakıldığında seçili 80 sensör ve seçili 120 sensörde olduğu gibi en yüksek ve en düşük sınıflandırma performansları aynı özellik ve özellik kombinasyonlarına aittir. Tüm sensörlerin seçili olduğu durumda diğer durumlara göre bütün performansların değerinde azalma olduğu görülmektedir.

Tablo 5. Seçili 80 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları

Özellikler	Başarım	Özellikler	Başarım
SGN+ KOK + DB	99.52	DB +DD+ SGA +	97.80
SGN +OMD+AR	99.18	DB +SGD+SGDK	84.96
SGN +SD+DD	94.73	DB +SGÇDK+WG	99.12
SGN + SGA +SGD	81.01	OMD+SD+DD	94.23
SGN +SGDK+SGÇDK	99.20	OMD+ SGA +SGD	80.74
EİD+ DB +OMD	99.39	OMD+SGDK+SGÇDK	99.15
EİD+AR+SD	94.97	AR+WD+ SGA	96.83
EİD+DD+ SGA	99.32	AR+SGD+SGDK	88.59
EİD+SGD+SGDK	83.84	AR+SGÇDK+WG	94.60
EİD+SGÇDK+WG	99.26	SD+ SGA +SGD	83.33
KOK +MAV+AR	98.62	SD+SGD+SGDK	99.29
KOK +SD+DD	94.39	DD+SGD+SGDK	96.71
KOK + SGA +SGD	80.98	DD+SGÇDK+WG	82.49
KOK +SGDK+SGÇDK	99.17	SGA +SGDK+SGÇDK	83.35
DB +AR+SD	96.73	SGD+SGÇDK+WG	99.03

Tablo 5'e bakıldığında seçili 80 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları görülmektedir. En yüksek sınıflandırma performansı sıfır geçiş, karekök ortalama ve dalga uzunluğu özelliklerinin kombinasyonlarına aittir. Bunun yanında en düşük sınıflandırma performansı ise ortalama mutlak değer ve sıfır geçiş özelliğinin farklı iki türevi kombinasyonlarına aittir.

Tablo 6. Seçili 120 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları

Özellikler	Başarım	Özellikler	Başarım
SGN + KOK +DB	99.52	DB +DD+ SGA +	97.95
SGN +OMD+AR	99.15	DB +SGD+SGDK	85.86
SGN +SD+DD	94.61	DB +SGÇDK+WG	99.45
SGN + SGA +SGD	82.01	OMD+SD+DD	93.79
SGN +SGDK+SGÇDK	99.54	OMD+ SGA +SGD	82.43
EİD+ DB +OMD	99.20	OMD+SGDK+SGÇDK	99.52
EİD+AR+SD	94.88	AR+DD+ SGA	93.18
EİD+DD+ SGA	99.42	AR+SGD+SGDK	88.42
EİD+SGD+SGDK	85.76	AR+SGÇDK+WG	94.54
EİD+SGÇDK+WG	99.66	SD+ SGA +SGD	84.58
KOK +OMD+AR	98.60	SD+SGD+SGDK	99.58
KOK +SD+DD	94.26	DD+SGD+SGDK	83.50
KOK + SGA +SGD	81.95	WT+SGÇDK+WAMP	99.35
KOK SGD+SGÇDK	99.60	SGA +SGDK+SGÇDK	85.39
DB +AR+DD	93.10	SGD+SGÇDK+WG	99.42

Tablo 6’da seçili 120 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma başarımlarına etkisi verilmiştir. Tablodaki değerlin seçili 80 sensördeki değerlere çok yakın olduğu görülmektedir. En yüksek başarımlar seçili 80 sensörde olduğu gibi sıfır geçiş, karekök ortalama ve dalga uzunluğu kombinasyonlarına aittir. Genel olarak sıfır geçiş özelliğinin ve türevlerinin sınıflandırma performanslarında etkilerini yüksek olduğu görülmektedir.

Tablo 7’de tüm sensörlerin (128 sensör) aktif halde iken özelliklerin üçlü kombinasyonlarının sınıflandırma performansları gösterilmiştir. Seçili 80 ve 120 sensördeki özelliklerin üçlü kombinasyonlarının sınıflandırma performanslarının tüm sensörler aktif iken genel olarak düştüğü görülmektedir. En yüksek başarımlar diğer durumlarda olduğu gibi sıfır geçiş, karekök ortalama ve dalga uzunluğu kombinasyonlarından elde edilmiştir.

Tablo 7. Seçili 128 sensörde özelliklerin üçlü kombinasyonlarının sınıflandırma performansları

Özellikler	Başarım	Özellikler	Başarım
SGN + KOK + DB	99.24	DB + DD + SGA +	97.51
SGN + OMD + AR	99.15	DB + SGD + SGDK	83.13
SGN + SD + DD	92.32	DB + SGÇDK + WG	98.78
SGN + SGA + SGD	79.39	OMD + SD + DD	91.44
SGN + SGDK + SGÇDK	98.91	OMD + SGA + SGD	80.57
EİD + DB + OMD	99.06	OMD + SGDK + SGÇDK	98.81
EİD + AR + SD	92.19	AR + DD + SGA	90.70
EİD + DD + SGA	98.84	AR + SGD + SGDK	85.73
EİD + SGD + SGDK	82.71	AR + SGÇDK + WG	92.14
EİD + SGÇDK + WG	99.20	SD + SGA + SGD	82.65
KOK + OMD + AR	98.18	SD + SGD + SGDK	99.02
KOK + SD + DD	91.49	DD + SGD + SGDK	81.04
KOK + SGA + SGD	80.30	DD + SGÇDK + WG	98.56
KOK + SGDK + SGÇDK	98.97	SGA + SGDK + SGÇDK	82.47
DB + AR + SD	89.67	SGD + SGÇDK + WG	98.78

Tablo 8, Tablo 9 ve Tablo 10' a bakıldığında özelliklerin dördü kombinasyonlarının sınıflandırma başarımlarına etkisi görülmektedir. Özelliklerin üçlü ve dördü kombinasyon sayılarının çok fazla olmasından dolayı bu tez içerisinde başarımlar oranları, diğer kombinasyonlara göre en yüksek ve karşılaştırma yapabilmek amacıyla en düşük değerler seçilerek verilmiştir. Tablo 8'e bakıldığında seçili 80 sensörde özelliklerin dördü kombinasyonlarının sınıflandırma performansları gösterilmiştir. En yüksek performans sıfır geçiş, karekök ortalama, dalga uzunluğu ve ortalama mutlak değer kombinasyonlarında görülmüştür. Burada üçlü kombinasyona ek olarak ortalama mutlak değer özelliğinin performansı arttırdığı görülmüştür.

Tablo 8. Seçili 80 sensörde özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları

Özellikler	Başarım	Özellikler	Başarım
SGN + KOK + DB + OMD	99.61	DB +SD+ DD + SGA	94.70
SGN +AR+SD+ DD	94.84	DD +SGD+SGDK+SGÇDK	85.28
SGN + SGA +SGD+SGDK	82.78	OMD + DD + SGA +SGD	94.23
EİD+ OMD +AR+SD	99.29	OMD+SGDK+SGÇDK+WG	86.41
EİD+ DD + SGA +SGD	95.51	AR+ SGA +SGD+SGDK	89.14
EİD+SGDK+SGÇDK+WG	85.16	SD+SGD+SGDK+SGÇDK	86.92
KOK +AR+SD+ DD	94.27	DD +SGDK+SGÇDK+WG	84.35
KOK + SGA +SGD+SGDK	83.33	SGA+SGD+SGDK+SGÇDK	99.32

Tablo 9’a bakıldığında seçili 80 sensöre göre seçili 120 sensörde dörtlü kombinasyonların genel olarak başarımı düşürdüğü gözlemlenmiştir. Ama yine de üçlü kombinasyonlara göre sınıflandırma performansı daha yüksektir.

Tablo 9. Seçili 120 sensörde özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları

Özellikler	Başarım	Özellikler	Başarım
SGN + KOK + DB + OMD	99.54	DB +SD+ DD + SGA	93.85
SGN +AR+SD+ DD	94.82	DD +SGD+SGDK+SGÇDK	85.60
SGN + SGA +SGD+SGDK	84.14	OMD +DD+ SGA +SGD	94.02
EİD+ OMD +AR+ST	99.21	OMD +SGDK+SGÇDK+WG	87.20
EİD+ DD + SGA +SGD	95.37	AR+ SGA +SGD+SGDK	89.05
EİD+SGDK+SGÇDK+WG	86.89	SD+SGD+SGDK+SGÇDK	87.10
KOK +AR+SD+ DD	93.63	DD +SGDK+SGÇDK+WG	84.96
KOK + SGA +SGD+SGDK	85.40	SGA+SGD+SGDK+SGÇDK	99.61

Son olarak Tablo 10’da 128 sensör de aktif durumda iken özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları verilmiştir. En az başarımın tüm sensörler aktif durumda iken olduğu net bir şekilde görülmektedir.

Tablo 10. Seçili 128 sensörde özelliklerin dörtlü kombinasyonlarının sınıflandırma performansları


Özellikler	Başarım	Özellikler	Başarım
SGN +KOK+ DB + OMD	99.27	DB +SD+DD+ SGA	91.53
SGN +AR+SD+ DD	92.62	DD +SGD+SGDK+SGÇDK	83.18
SG N+ZCA+SGD+SGDK	81.64	OMD + DD + SGA +SGD	91.56
EİD+ OMD +AR+SD	98.65	OMD+SGDK+SGÇDK+WG	84.09
EİD+ DD + SGA +SGD	93.13	AR+ SGA +SGD+SGDK	86.37
EİD+SGDK+SGÇDK+WG	84.02	SD+SGD+SGDK+SGÇDK	84.35
KOK +AR+SD+ DD	91.49	DD +SGDK+SGÇDK+WG	82.65
KOK + SGA +SGD+SGDK	83.35	SGA+SGD+SGDK+SGÇDK	99.03

Varyans hesaplaması ile sensör eliminasyonunun gerçekleştirilmesi EMG sinyalinin sınıflandırma performansına doğrudan etki ettiği yukarıda verilen sonuçlarda açık bir şekilde görülmektedir. Burada önemli olan varyans değerinin az olduğu çok sayıda sensörün elenmesi değildir. Önemi olan yüksek başarıyı elde edecek en etkisiz sensörlerin tespit edilip çıkarılmasıdır. Sonuçlara bakıldığında en yüksek başarımın en çok sensör elemesine sahip 80 sensör de değil, sadece 8 sensörün eliminasyonunun gerçekleştiği seçili 120 sensörde meydana geldiği görülmektedir. Aynı zamanda en yüksek sınıflandırma performansının ikili özellik kombinasyonunda olduğu görülmektedir. Bu durum EMG sinyalinin işlenmesinde özellik seçiminin ve özellik kombinasyonlarının etkisinin değerini ön plana çıkarmaktadır.

2.2. Topolojik Veri Analizi İle EMG Sinyal İşleme


EMG sinyal analizinde Makine öğrenmesi ve derin öğrenme algoritmaları dışında farklı bir bakış açısı sunan TVA son on yılda insan-bilgisayar etkileşimli çalışmalarda sıkça kullanılmaya başlanmıştır. Bundan dolayı EMG sinyal analizinde ikinci yaklaşım olarak Topolojik Veri Analizi kullanılarak EMG sinyallerinin topolojik özellikleri elde edilmiştir. Başlangıçta EMG verisi nokta bulutuna dönüştürülmüş ve uzayda temsil edilmiştir. Topolojik veri analizinde amaç nokta verileri arasındaki topolojik bağıntıyı oluşturarak, verilerden oluşturulan homoloji yapıları ile veriyi çıkarılma işlemi yapılmış ve derin öğrenme algoritmaları için görüntü oluşturulmuştur. İlk yöntemde, EMG verisinin topolojik yapıları incelenerek elde edilen simpleks, betti sayıları ve verilerin yaşam aralığı değerleri özellik olarak kullanılarak sınıflandırma işlemi yapılmıştır. İkinci çalışmada ise topolojik yapı kullanılarak verilerden elde edilen korelasyon matrisinin ısı haritası oluşturulmuş ve tez

kapsamında üçüncü yaklaşım olan derin öğrenme modeline girdi olarak verilerek analiz edilmiştir. TVA’da gerçekleştirilen işlemlerin akış şeması Şekil 23’te verilmiştir. Bu tez çalışması kapsamında veri setinde bulunan sekiz farklı el hareketini tanımlayabilmek için EMG sinyallerinin topolojik analizi yapılmış, elde edilen çıktılar özellik olarak kullanılarak makine öğrenme algoritmaları ile sınıflandırma yapılmıştır.



Şekil 23. EMG sinyali için topolojik veri analizi şeması

Nokta bulutu halindeki EMG verilerinden simpleks yapıları oluşturulmak için 0, 1 ve 2 simpleks yapıları elde edilmiştir. Bu değerler nokta, kenar ve üçgen yapılarına karşılık gelmektedir. Betti sayıları ise elde edilen simplikal kompleks yapısında parça sayısı, delik ve boşlukların sayılarından kaç tane olduğu anlamına gelmektedir. Örneğin simplikal kompleks 10 tane parçadan oluşuyor ise Betti0 değeri 10'a eşit olmaktadır. Benzer durumda simplikal kompleks 5 tane boşluk içeriyorsa Betti1 değeri 5'e eşit olmaktadır. Bu çalışma içerisinde 0,1 ve 2 simpleks yapıları elde edilmiştir ve 0. Ve 1. Boyuttaki betti değerleri ile işlem yapılmıştır. Bunun sebebi simpleks değeri arttıkça işlem hacmi ve süresinin artmasıdır.




Şekil 24. 1.Sınıfa ait EMG verisinin simplekslerinden oluşan homoloji grubu

Şekil 24'te EMG verisinin birinci sınıfına ait bir örneğinden elde edilen homoloji grubu gösterilmiştir. CapgMyo veri seti 560 örnek ve 128 kanal sayısına sahip olduğu için burada 128 tane noktadan oluşan bir homoloji grubu gösterilmiştir.

2.2.1. Barkod ve Kalıcılık Diyagramlarının Elde Edilmesi

TVA'da kullanılan iki önemli araç barkod ve kalıcılık diyagramlarıdır. Barkod diyagramları veri setindeki topolojik özelliklerin yaşam süresini ifade eden bir grafik


türüdür. Her bir topolojik özellik bir doğum ve ölüm zamanına sahiptir. Şekil 25'te 1. sınıfa ait bir örneğin barkod diyagramı verilmiştir. Karşılaştırma yapılabilmesi için Şekil 26 ve Şekil 27'de sırasıyla 2. ve 3. sınıfa ait örneklerden de birer barkod diyagramı gösterilmiştir. Barkod diyagramlarında verilen 0.boyut ve 1.boyut değerleri $Betti_0$ ve $Betti_1$ değerlerine karşılık gelmektedir.




Şekil 25. 1.Sınıfa ait bir örneğin barkod diyagramı

İşlem süresi uzunluğu ve işlem hacminin büyük olmasından dolayı sadece $Betti_0$ ve $Betti_1$ değerleri dikkate alınmıştır. 0. boyut parça sayısını temsil ettiğinden dolayı barkod diyagramlarında 128 tane parça sayısı bulunmaktadır. Bu bağlamda $Betti_0$ değeri 128'e eşittir. Filtrasyon değeri ise ölçek değeri anlamına gelmektedir. Her bir nokta etrafında filtrasyon değerinde bir halka çizildiği düşünülerek halkaların kesiştiği durumlarda simpleks yapılarının oluştuğu kabul edilir. Burada filtrasyon değeri sıfırdan başlatılmış ve 0.1 değerinde arttırılarak devam edilmiştir. Bu değer seçilmesinin sebebi anlamlı sayıda simpleks değerini elde etmektedir. Ölçek aralığı arttırıldığında oluşacak simpleks sayısında azalma meydana gelecektir. Bu durum topolojik özelliklerin elde edilmesinde olumsuz etki

sağlayacaktır. Ölçek aralığının belirli bir değerin altında olması işlem hacmini ve süresini arttıracaktır. Buna karşılık simplekslerin oluşmasında gecikme yaşanacaktır. Farklı ölçek aralığı değerleri karşılaştırılarak 0.1 değeri kullanılmıştır. 0.boyutta bütün veriler 0 ölçek değerinden başlamış ve belli bir ölçek değerinde yok olmuştur. Bunun sebebi 0.boyut 0 simpleks değerinde parça sayısını temsil ettiği için zaten başlangıçta 0 simpleks değeri haricinde bir simpleks değeri bulunmamasıdır.




Şekil 26. 2.Sınıfa ait bir örneğin barkod diyagramı



Şekil 27. 3.Sınıfa ait bir örneğin barkod diyagramı


Barkod diyagramlarında 1.boyut yani Betti1 değerlerine bakıldığında sıfırdan farklı bir filtrasyon değerinde ortaya çıkmış ve belli bir zaman sonra yok olmuş topolojik yapılar görülmektedir. 3 farklı sınıfa ait 1.boyut verilerine bakıldığında farklı filtrasyon değerlerinde oluşmuş ve farklı filtrasyon değerlerinde yok olmuş noktalar görülmektedir.

TVA’da kalıcılık diyagramları barkod diyagramlarından faydalananarak oluşturulmuş diyagramlardır. Kalıcılık diyagramları topolojik özelliklerin ortaya çıkış ve yok oluş zamanlarını göstermektedir. Kalıcılık diyagramlarındaki zaman kavramı filtrasyon değerine karşılık gelmektedir. Bu çalışma içerisinde barkod diyagramlarından kalıcılık diyagramları elde edilerek EMG verisinin topolojik özellikleri analiz edilmiştir.




Şekil 28. 1.Sınıfa ait bir örneğin kalıcılık diyagramı

TVA’da verilerinin yeni topolojik özelliklerin oluşması doğum zamanı, topolojik özelliklerin yok oluşu ölüm zamanı olarak tanımlanmaktadır. Burada oluşturulan kalıcılık diyagramları EMG verisinden elde edilen topolojik özelliklerin doğum ve ölüm zamanlarını içermektedir. Kalıcılık diyagramlarında dikey eksen ölüm zamanını temsil ederken yatay eksen doğum zamanını temsil eder. Her bir verinin kalıcılık diyagramı üzerinde bulunduğu konumu topolojik özelliği, kalıcılığı hakkında bilgi vermektedir. Şekil 28’de 1.sınıfa ait bir örneğin 0. Boyut ve 1.boyut kalıcılık diyagramları gösterilmiştir. Karşılaştırma yapılabilmesi amacıyla Şekil 29 ve Şekil 30’da 2 ve 3. sınıfa ait kalıcılık diyagramlarında birer örnek verilmiştir.



Şekil 29. 2.Sınıfa ait bir örneğin kalıcılık diyagramı



Şekil 30. 1.Sınıfa ait bir örneğin kalıcılık diyagramı

Kalıcılık diyagramlarına bakıldığında her bir verinin oluşturduğu topolojik özelliğin ne zaman doğduğu ve ne zaman öldüğü görülmektedir. Bu durum, ilgili topolojik özelliğin kalıcılığının hakkında bilgi vermektedir. 0. boyut kalıcılık diyagramında her bir nokta 0 zamanında doğmuştur ve belli bir zaman sonra ölmüştür. Bu nedenle 0. boyut kalıcılık diyagramında bütün değerler dikey eksen üzerindedir. 1. boyut kalıcılık diyagramlarına bakıldığında topolojik özellikler sıfırdan farklı bir zamanda doğmuş belli bir zaman sonra ölmüştür. Bütün şartlar altında doğum zamanı ölüm zamanından önce olacağından dolayı veriler $y=x$ doğrusunun üzerinde yer almaktadır. Bir veri bu eksenden ne kadar uzaksa kalıcılığı diğer verilere göre daha fazladır.

EMG verilerinden elde edilen topolojik özellikler olan 0.boyut yaşam süresi ve 1.boyut yaşam süreleri öznitelik olarak kullanılıp el hareketleri MATLAB programı ile sınıflandırılmıştır. 5'li çapraz doğrulama yönteminde kullanılmıştır.


Tablo 11. Topolojik özellikler kullanılarak sınıflandırılan EMG verisinin sınıflandırma sonuçları

Özellik	Doğrulama D. (%)		Gözlem/Saniye
	k-EYK	DVM	
0.Boyut Yaşam S.	70.26	59.8	1100
1.Boyut Yaşam S.	32.21	22.56	1240

Uygulamada bulunan farklı sınıflandırma algoritmaları kullanılmıştır. En yüksek başarımlar K En Yakın Komşu algoritması ile elde edilmiştir. Tablo 11'de kullanılan topolojik özellikler, doğrulama doğrulukları, eğitim süresi ve saniyedeki tahmin gözlem sayıları verilmiştir. 1. Boyut yaşam süresinde %32.21 doğruluk elde edilirken 0.boyut yaşam süresinde %70.26 doğruluk elde edilmiştir. Eğitim sürelerinin oldukça düşük ve saniyedeki tahmin gözlem sayısının oldukça yüksek olduğu açık bir şekilde görülmektedir.

2.3. Derin Öğrenme Algoritmaları ile EMG sinyal İşleme


EMG sinyallerinin derin öğrenme modelleri kullanılarak incelenmesi sinyal işleme ve sınıflandırma alanlarında oldukça önemli bir yere sahiptir. Derin öğrenme modelleri büyük boyutta veri setleri üzerinde eğitildiklerinde EMG sinyallerinden etkili özellikler çıkarılması mümkün olmaktadır. Derin öğrenme modellerinin bir görevde eğitildiklerinde başka bir görevde de kullanılması farklı veri setleri üzerinde yapılacak çalışmaların değerini arttırmaktadır. Bu tez çalışması kapsamında Şekil 31’de verilen akış şeması takip edilerek ham EMG sinyali önce görüntüye çevrilmiştir. Daha sonra görüntüye çevrilen EMG sinyallerinden özellik çıkarımı gerçekleştirilmiştir ve son olarak kapsül ağına verilerek sınıflandırılmıştır.



Şekil 31. Sistem akış şeması

2.3.1. EMG Sinyalinin Görüntüye Dönüştürülmesi

Bu çalışma kapsamında EMG verilerini görüntüye çevirmek için Sürekli Dalgacık Dönüşümü kullanılmıştır. Sürekli Dalgacık Dönüşümü sinyal temsilini gerçekleştirmek amacıyla dalgacıkların çeviri ve ölçek parametrelerini sürekli bir şekilde modifiye ederek kullanılan bir analiz aracıdır. Çeşitli dalgacık türleri arasından sinyalin sıkışıklığını ve genlik değişikliklerini daha iyi tespit edebilmek için Morse dalgacığı seçilmiştir ve buradaki işlemde kullanılmıştır. Örnekleme frekansı, sinyal uzunluğu, oktav parametreleri sırasıyla 256 Hz, 1000 s, 10 olarak belirlenmiştir. Oluşacak olan her görüntü derin öğrenme modellerine girdi olarak verileceğinden görüntüler 224x224 olarak boyutlandırılmıştır.



Şekil 32. Birinci sınıfa ait ham EMG verisi (a) ve skalogram görüntüsü (b)

Şekil 32’de ham EMG sinyali ve görüntüye çevrilen EMG sinyalin skalogramı gösterilmiştir. Bu skalogram veri setinin 1. sınıfına ait bir örneğin görüntüsünü içermektedir.

2.3.1. Derin Öğrenme Modelleri ile Özellik Çıkarımı

Özellik çıkarma işleminden önce görüntüye dönüştürülen EMG verisinin boyutları kapsül ağına girdi olarak verileceğinden dolayı düzenlenir. Görüntüye çevrilen EMG verileri

kapsül ağına girdi olarak verilmeden önce özellik çıkarma işlemine tabii tutulur. Tez çalışması kapsamında veriler önceden eğitilmiş ESA olan VGG19, EfficientNetB0 ve EfficientNetB4 kullanılarak özellikler çıkarılmıştır. Önceden eğitilmiş bu modellerden genel bilgiler kısmında bahsedilmiştir. EfficientNetB0 ve EfficientNetB4 eğitilmiş modellerinin özellik çıkarma işlemi için, modellerin ilk üç katmanı kullanılmaktadır. Bu modeller önceden eğitilmiş ağırlıklarla yüklüdür ve geniş bir veri kümesi üzerinde önceden öğrenilmiş özellik çıkarma yeteneklerine sahiptir. Bu sebeple bu modeller sınırlı ve belirli katmanları kullanarak hızlı ve etkili bir şekilde özellik çıkarma işlemini gerçekleştirir.

Özellik çıkarımı için kullanılan bir diğer eğitilmiş model VGG19'dur. Şekil 26'da özellik çıkarımı için VGG19 modelinin kullanıldığı katmanlar görülmektedir. Başlangıçta 3x3 boyutlarında 1 adet evrişim (convolution) katmanı kullanılmıştır. Burada Kernel operatörü kullanılmıştır. Kernel filtresi bir evrişim katmanında sık kullanılan bir matris türüdür. Bu matris girdi verisi üzerinde kaydırılıp belirli hesaplamalar yapar ve özellik haritalarını meydana getirir. Bu katmanda Kernel filtresi 64 kere uygulanır. Ve her bir filtrenin EMG görüntüsündeki farklı özellikleri yakalamasına yardımcı olur. Bu katmandan sonra 2x2 boyutunda maksimum havuzlama (max pooling) katmanı kullanılmıştır. Bu katman ESA'da sıkça kullanılan katmanlardan bir tanesidir. Bu katmanda EMG görüntüsünün boyutunu azaltarak hesaplama maliyetini azaltır ve önemli özelliklerin korunmasını sağlar. 2x2 boyutu havuzlama penceresinin boyutu ifade eder. Bu katmanda EMG görüntüsü 2x2 boyutunda alt bloklar üzerinde kaydırılır. Her bloktaki maksimum değer belirlenir ve özellik haritasına aktarılır. Bu katmandan sonra 3x3 boyutunda iki kez tekrarlayan ve filtre sayısı 128 olan evrişim katmanı kullanılmıştır. Devamında ise tekrar 2x2 boyutundan maksimum havuzlama katmanı kullanılmıştır. Son olarak 3x3 boyutunda filtre sayısı 256 olan ve 3 kez tekrarlayan evrişim katmanı kullanılarak tekrar maksimum havuzlama katmanı ile özellik çıkarma işlemi tamamlanmıştır.

2.3.2. Kapsül Ağı Modeli

Kapsül ağları geleneksel olarak kullanılan evrişimli sinir ağlarının yanı sıra verinin pozisyonel ve yönelimsel bilgisini daha iyi yakalar. Kapsüller, sadece varlık bilgisi değil aynı zamanda bu varlıkların pozisyon ve oryantasyon gibi özelliklerini de öğrenir. Bu, EMG verileri gibi karmaşık ve yüksek boyutlu verilerde kritik öneme sahiptir, çünkü bu tür

verilerde farklı kas aktivitelerinin konumu ve yönelimi sınıflandırma performansını etkileyebilir. Bu çalışma kapsamında kullanılan kapsül ağı modeli şekil 27’de gösterilmiştir.

Kapsül ağları, verinin hiyerarşik yapısını daha iyi öğrenir. Bu, EMG verilerindeki kas hareketlerinin ve aktivitelerinin daha doğru bir şekilde sınıflandırılmasına yardımcı olur.

EMG verileri karmaşıklığı ve dinamik doğası gereği, geleneksel olarak kullanılan evrişimli sinir ağlarının ötesinde bir mimariye ihtiyaç duyar. Kapsül ağları, bu verilerin pozisyonel ve yönelimsel bilgilerini etkili bir şekilde yakalayarak daha doğru ve anlamlı sınıflandırma sonuçları elde etmeye yardımcı olmuştur. Ayrıca, EMG sinyallerinin farklı varyasyonları üzerinde daha iyi performans göstermesi, bu ağı tercih edilmesinde önemli bir etken olmuştur.

Sonuç olarak, VGG19, EfficientNetB0 ve EfficientNetB4 modelleri ile çıkarılan özellikler kapsül ağına girdi olarak vererek, EMG verilerinin daha doğru ve etkili bir şekilde sınıflandırılmasını sağlanmıştır. Kapsül ağlarının sunduğu hiyerarşik öğrenme yeteneği ve pozisyonel bilgileri koruma özelliği, sınıflandırma performansını önemli ölçüde arttırmıştır.

2.3.1. Derin Öğrenme Modeli için Parametrelerin Düzenlenmesi


Makine öğrenmesi ve derin öğrenme modellerinin eğitimi sırasında kullanılan parametreler, modelin performansını, verimliliğini ve genelleme yeteneğini belirleyen önemli faktörlerdir. Bu parametreler, modelin her aşamasında çeşitli ayarlamalar yapmayı mümkün kılar ve doğru kullanıldığında, modelin daha hızlı, daha doğru ve daha güvenilir sonuçlar üretmesine yardımcı olur. Tablo 12’de kapsül ağı için kullanılan parametreler ve değerleri verilmiştir.

Tablo 12. Kapsül ağında kullanılan parametreler ve değerleri

Parametre Türü	Parametre Değeri
Küme boyutu	12
Görüntü boyutu	300
Epok	100
Öğrenme oranı	0.001
Beta1	0.9
Bırakma Yüzdesi	0.05


Küme boyutu (batch size) her eğitim adımında kullanılan EMG verisi örneğini içerir ve 12 olarak seçilmiştir. Bu değerin seçilmesinde tez kapsamında kullanılan bilgisayarın GPU (Graphics Processing Unit) değeri etkili olmuştur. Görüntü boyutu (image size) kapsül ağına girdi olarak verilen EMG görüntüsünün boyutunu belirler ve 300 olarak seçilmiştir. Epok (epochs) sayısı modelin kaç kere eğitileceği anlamına gelir ve değeri 100 olarak belirlenmiştir. Kapsül ağında optimizasyon olarak ADAM optimizasyonu kullanılmıştır ve birinci moment tahmin parametresi olan beta1 değeri 0.9 olarak belirlenmiştir. Öğrenme oranı (learning rate) modelin her bir epokta öğrenme oranını belirtir ve 0.001 seçilmiştir. Bu değer optimizasyon sürecinin hızını belirtir. Dropout (bırakma) değeri dropout katmanını için bir oran belirtir. Aşırı öğrenmeye önlemeye çalışır ve modelin genelleme yeteneğine olumlu katkıda bulunur.

Çalışmanın bu kısmında derin öğrenme algoritmaları kullanılarak EMG sinyal analizindeki sonuçları verilmiştir. EMG görüntülerinden özellik çıkarımı için önceden eğitilmiş VGG19, EfficientNetB0 ve EfficientNetB4 derin öğrenme modelleri kullanılmıştır. Bu modeller için eğitim, doğrulama doğrulukları ve kayıpları ayrı ayrı verilmiştir. Şekil 33'te EfficientNetB0 için eğitim ve doğrulama doğrulukları verilirken Şekil 34'de eğitim ve doğrulama kayıpları verilmiştir.




Şekil 33. EfficientNetB0 için eğitim ve doğrulama doğrulukları

Ortalama 20. epoktan sonra doğrulama doğruluğunun %90'ının üzerine çıktığı görülmektedir. Doğrulama kayıplarının ise %8'lerden başlayıp %5'lere düştüğü görülmektedir.




Şekil 34. EfficientNetB0 için eğitim ve doğrulama kayıpları

Şekil 35 ve Şekil 36'da EfficientNetB4 için eğitim, doğrulama doğrulukları ve kayıpları verilmiştir. Grafiklere bakıldığında EfficientB0'a göre doğrulama doğruluklarının arttığı görülmektedir. Aynı zamanda doğrulama kayıplarının da azaldığı görülmektedir.




Şekil 35. EfficientNetB4 için eğitim ve doğrulama doğrulukları




Şekil 36. EfficientNetB4 için eğitim ve doğrulama kayıpları

Şekil 37 ve Şekil 38’de ise özellik çıkarma işlemi olarak VGG19 eğitilmiş derin öğrenme modelinin kullanıldığı modelin eğitim, doğrulama doğrulukları ve kayıpları verilmiştir. Sonuçlar incelendiğinde doğrulukların EfficientNet modellerine göre daha da arttığı görülmektedir.



Şekil 37. VGG19 için eğitim ve doğrulama doğrulukları



Şekil 38. VGG19 için eğitim ve doğrulama kayıpları

VGG19 modelinin bu çalışmada kullanılan en etkili model olduğu görülmektedir. Her bir modelin en iyi sonuçları ve kayıpları Tablo 13’de verilmiştir.

Tablo 13. Farklı özellik çıkarma modelleri için eğitim, başarımları ve kayıpları

Özellik Çıkarma Modeli	Başarımları (%)	Doğrulama K. (%)
EfficientNetB0	94.64	5.25
EfficientNetB4	97.32	5.24
VGG19	99.11	5.28

Derin öğrenme modelleri, biyomedikal sinyal işleme alanında önemli bir dönüşüm sağlamaktadır. Özellikle EMG sinyallerinin işlenmesinde kullanıldığında, bu modellerin sağladığı avantajlar çeşitli boyutlarda değerlendirilebilir. Sonuçlar göstermektedir ki, EfficientNet ve VGG19 gibi derin öğrenme modelleri, EMG sinyallerini etkili bir şekilde işleyerek yüksek başarı oranları elde etmektedir. EfficientNet modellerinin %94.64 ve %97.32 gibi yüksek başarı oranları, bu modellerin EMG sinyallerinin karmaşıklığını ve dinamik yapısını yakalamadaki etkinliğini göstermektedir. Bu modeller, verinin hiyerarşik yapısını keşfederek, önemli özellikleri belirlemede ve sınıflandırmada üst düzey bir performans sergilemektedir. Ayrıca, bu modellerin hafif ve hesaplama açısından verimli

olması, gerçek zamanlı uygulamalarda da tercih edilmelerini sağlamaktadır. Öte yandan, VGG19 gibi daha geleneksel bir mimariye sahip derin öğrenme modelleriyle elde edilen %99.11 gibi yüksek bir başarı oranı, bu modelin derinlemesine ve karmaşık özellikleri daha iyi öğrenme yeteneğini vurgular. VGG19'un çok katmanlı yapısı, EMG sinyallerinin daha derin ve kapsamlı bir şekilde işlenmesine imkân tanır ve bu da daha yüksek doğruluk ve güvenilirlik sağlar.


Kapsül ağları, özellik çıkarımı sürecinden sonra elde edilen temsilleri daha anlamlı ve yorumlanabilir bir şekilde sunmuştur. Bu, EMG sinyallerinin analizinde hangi özelliklerin model tarafından vurgulandığını ve nasıl yorumlandığını daha iyi anlamamıza yardımcı olmuştur. Özellik çıkarımı sürecinde elde edilen temsilleri daha az sayıda parametre ile temsil edebilmiştir. Bu, modelin daha hafif olmasını sağlamıştır ve mobil veya gömülü sistemler gibi kaynak kısıtlı ortamlarda kullanımı daha pratik hale getirebilmektedir.

Sonuçlar gösteriyor ki, daha doğru sınıflandırma, tanıma ve tahminlerin yapılması kapsül ağları ile mümkün ve sağlık endüstrisi gibi kritik alanlarda güvenilir sonuçlar elde edilmesini sağlayabilir.

Gelecekte, bu modellerin daha da geliştirilmesi ve optimize edilmesi, EMG sinyallerinin daha kapsamlı bir şekilde analiz edilmesini sağlayarak, sağlık hizmetlerindeki etkinliği ve erişilebilirliği artırabilir.

2.3.2. Korelasyon Matrislerinin Isı Haritalarının Çıkarılarak Derin Öğrenme Modelleri ile Sınıflandırılması

Bu çalışmada, EMG verisinden elde edilen korelasyon matrislerinin analizi üzerine odaklanıldı. Korelasyon matrisleri, EMG sinyallerinin farklı sensörler arasındaki ilişkilerini ölçmek için kullanılmaktadır. Bu korelasyon matrisleri Şekil 39'da gibi ısı haritasına dönüştürülerek görüntüye dönüştürülmektedir. Isı haritaları, farklı elektrot çiftleri arasındaki korelasyonun görsel bir temsili olarak kullanıldı. Böylece, EMG sinyallerinin bölgesel bağlantılarını ve ilişkilerini daha iyi anlamak için görsel bir araç sağlandı.



Şekil 39. Korelasyon matrisinin ısı haritası

Elde edilen ısı haritalarının VGG19 modeli ile özellikleri çıkarılarak kapsül ağına girdi olarak verildi. Sonuçlar Tablo 14’te gösterilmiştir.

Tablo 14. Korelasyon matrislerinden elde edilen ısı haritalarının derin öğrenme modeli için eğitim, doğrulama doğrulukları ve kayıpları

Özellik Çıkarma Modeli	Başarım (%)	Doğrulama K. (%)
VGG19	97.32	5.17

Sonuçlar göstermektedir ki, korelasyon matrislerinin ısı haritalarına dönüştürülmesi, EMG sinyallerinin farklı sensörler arasındaki ilişkilerini görsel olarak temsil etmek için güçlü bir araçtır. Isı haritaları, farklı sensör çiftleri arasındaki korelasyonu belirgin bir şekilde gösterebilmektedir. Bu yaklaşım, EMG verisinin analizinde kullanılabilecek değerli bir araç olabilir ve gelecekteki çalışmalarda daha geniş veri kümeleriyle ve çeşitli uygulamalarla daha da keşfedilebilir.

3. SONUÇLAR

Biyomedikal sinyallerin yapay zekâ algoritmaları kullanılarak işlenmesi başta tıbbi teşhis ve tedavi yöntemlerinde, rehabilitasyon işlemlerinde, işaret dili uygulamalarında, uzaktan kontrol edilebilir uygulamalarda, protez ve implant uygulamalarında, el-yüz hareketlerini tanıma sistemlerinde ve insan bilgisayar etkileşimi gibi birçok alanda yaygın bir şekilde kullanılmaktadır. Bu tez çalışması kapsamında bir biyomedikal sinyal olan EMG sinyalleri ele alınmıştır.

Tez çalışmasının amacı farklı yaklaşımlar ile EMG sinyallerini analiz ederek elde edilen sonuçların karşılaştırılmasının yapılması ve gerekli çıkarımların elde edilmesidir. Bu bağlamda 128 kanallı ve 8 farklı el hareketini içeren CapgMyo veri seti ele alınmış ve farklı yaklaşımlar ile kullanılmıştır.

EMG sinyallerini analiz etmek için bu tez çalışmasında geleneksel makine öğrenmesi algoritmaları, topolojik veri analizi, derin öğrenme modelleri yaklaşımları kullanılmıştır. Her bir yaklaşımın kendi içerisindeki genel bakışı, akış diyagramı, kullanılan yöntemleri ve çıktıları tez içerisinde sunulmuştur. Aynı şekilde her bir çalışma içerisinde elde edilen sonuçlar Tablo 15'te bir arada gösterilmiştir.

İlk yaklaşım olarak EMG sinyalleri geleneksel makine öğrenmesi algoritmaları kullanılarak analiz edilmiştir. Başlangıçta EMG sinyalleri pencereleme yöntemi ile veri setinin boyutu genişletilmiştir. Buradaki amaç veriyi daha anlamlı ve etkili bölümlere ayırmaktır. Boyutu artırılan verinin 128 sensörü içerisinde en etkili elektriksel aktivite bilgisine sahip sensörleri elde edilmeye çalışılmıştır. 128 sensörün varyansı hesaplanılmış ve küçükten büyüğe doğru sıralanmıştır. Çeşitli denemeler sonucunda varyans değeri en etkili sırasıyla 80, 120 ve 128 (tüm sensörler) ele alınarak EMG sinyalleri analiz edilmiştir. Bu çalışmaya ek olarak 13 farklı öznitelik ile EMG sinyalleri tek tek, ikili, üçlü ve dörtlü öznitelik kombinasyonları ile özellik çıkarımı gerçekleştirilmiştir. Basit, uygulanabilir ve genellikle yüksek boyutlu özellik vektörleriyle kullanıldığında ölçeklenebilirlik avantajı sunduğu için bu çalışmada K- En Yakın Komşu sınıflandırma algoritması kullanılmıştır. Elde edilen sonuçlara bakıldığında en yüksek başarımın ikili öznitelik kombinasyonu ile seçili 120 sensörde olduğu görülmüştür. Buradaki öznitelik çifti sıfır geçiş ve eğim işareti değişimidir ve başarım oranı %99.75 olarak elde edilmiştir. 128 sensör içerisinde

elektiriksel aktivite bilgisi en az olan 8 sensörün elenmesi başarıım oranındaki artışta etkili olmuştur.

Tablo 15. Önerilen tüm yaklaşımlar ve başarıım yüzdeleri

Önerilen Modeller	Başarıım (%)
Makine Öğrenmesi Algoritmaları ile EMG Sinyal Analizi	99.75
Topolojik Veri Analizi ile EMG Sinyal Analizi	70.26
Derin Öğrenme Modelleri ile EMG Sinyal Analizi	99.11

İleri matematik alanında sıkça kullanılan bir yöntem olan topolojik veri analizi son 10 yılda makine ve derin öğrenmesi alanında yaygın bir şekilde kullanılmaya başlanmıştır. Bu motivasyon ile ikinci yaklaşımda EMG veri setinin topolojik özellikleri analiz edilmiştir. Öncelikle EMG verileri nokta bulutuna dönüştürülerek temsil edilmiştir. Nokta bulutu halindeki verinin Vietoris-Rips yöntemi ile simpleks yapıları elde edilmiştir. Bu yaklaşım içerisinde işlem hacminin büyük olması sebebiyle simpleks değerleri sadece $k=0$ ve $k=1$ için elde edilmiştir. Simpleks yapıları elde edilen EMG verisinin homoloji grupları oluşturulmuştur. Elde edilen simpleks yapıları sayesinde veri setinin barkod ve kalıcılık diyagramları elde edilmiştir. Bu diyagramlar ile veri setinde oluşan topolojik desenler hakkında bilgi edinilmiştir. Bu topolojik desenlerin ortaya çıkış ve yok oluş zamanları dikkate alınarak EMG sinyallerini işlemede özellik olarak kullanılmıştır. $k=0$ simpleks değerine karşılık gelen 0.boyut ve $k=1$ simpleks değerine karşılık gelen 1.boyut yaşam süreleri elde edilerek analiz gerçekleştirilmiştir. MATLAB ortamında EMG sinyalleri sınıflandırma algoritmalarının tamamı ile sınıflandırılmış ve en yüksek başarımlar K-En Yakın Komşu sınıflandırma algoritması ile elde edilmiştir. 1.boyut yaşam süreleri özellik olarak kullanıldığında %32.21 başarıım oranı elde edilirken 0.boyut yaşam süreleri özellik olarak kullanıldığında %70.26 başarıım oranı elde edilmiştir. Burada eğitim süresinin 2.17 saniye gibi kısa bir sürede gerçekleştiği aynı zamanda saniyedeki gözlem sayısının 1100 gibi yüksek bir değerde olması göze çarpmıştır.

Üçüncü ve son yaklaşım derin öğrenme modelleri ile EMG sinyalleri analiz edilmiştir. Derin öğrenme modelleri genel olarak büyük boyuttaki veri setleri üzerinde eğitildiklerinde

önemli ölçüde olumlu sonuçlar verebilmektedir. Bu yaklaşım içerisinde öncelikle EMG sinyalleri görüntüye çevrilmiştir. Daha sonra önceden eğitilmiş modeller olan EfficientNetB0, EfficientNetB4 ve VGG 19 modelleri ile EMG görüntülerinin özellikleri çıkarılmıştır. Sonrasında özellik matrisleri, derin öğrenme modelleri içerisinde etkili sonuçlar ortaya koymuş ve koymaya devam eden kapsül ağına girdi olarak verilmiştir. Görüntülerin pozisyonel ve yönelimsel bilgilerini iyi yakalayan kapsül ağı modeli ile EMG görüntüleri sınıflandırılmıştır. Özellik çıkarma işlemi için VGG19 önceden eğitilmiş modelin kullanıldığı deneyde en yüksek başarımlar oranı %99.11 olarak elde edilmiştir.

Ayrıca bu çalışma içerisinde farklı bir yaklaşım olarak EMG verisinin sensör çiftleri arasındaki korelasyon matrisleri hesaplanarak ısı haritaları elde edilmiştir. Korelasyon haritasından elde edilen ısı haritaları görüntü olarak kullanılıp daha önce en yüksek başarımın elde edildiği VGG19 modeli ile özellik çıkarımı gerçekleştirilmiştir. Bir önceki çalışmada olduğu gibi özellik matrisleri kapsül ağına verilip sınıflandırılmıştır. Bu çalışmada başarımlar oranı %97.32 olarak elde edilmiştir.

Çalışma içerisinde farklı yaklaşımların kullanılması, bu alanda daha önce yapılmış ve yapılacak olan diğer çalışmalar ile karşılaştırılma yapılabilmesini sağlamıştır. Elde edilen etkili ve yüksek başarımdaki sonuçların literatüre ve gelecekte yapılacak diğer çalışmalara katkıda bulunacağı temenni edilmektedir.

4. ÖNERİLER

Yüksek lisans tezi olarak sunulan bu çalışmada, makine öğrenmesi algoritmaları, topolojik veri analizi ve derin öğrenme modelleri ile EMG sinyallerinin analizi gerçekleştirilmiştir. Bu çalışma kapsamında ilişkili olabilecek bu alanda çalışma ve uygulama yapmak isteyen araştırmacılara ve uygulayıcılara aktarılacak öneriler aşağıda sıralanmıştır:

- EMG sinyal analizi için kullanılacak olan makine öğrenmesi algoritmalarında, farklı özneliklerin kullanımı, eğitim ve doğrulama başarısını artırmaya olanak sağlayabilmektedir. Bu sebeple EMG sinyalinin farklı ve etkili öznelikleri tespit edilebilir.
- Tez içerisinde topolojik veri analizinde 0. ve 1. boyut yaşam süreleri için analiz yapılmıştır. İşlem hacmini karşılayacak teçhizatların kullanımı ile daha yüksek boyuttaki yaşam süreleri değerlerinde analiz daha etkili sonuçlar elde edilebilir.
- Topolojik veri analizinde betti değerleri özellik olarak kullanılarak biyomedikal sinyallerin analizi yapılabilir.
- Özellik çıkarımı uygulaması için tez içerisinde önceden eğitilmiş EfficientNetB0, EfficientNetB4 ve VGG19 modelleri kullanılmıştır. Önceden eğitilmiş farklı modellerin ve etkili katmanların kullanımı ile daha etkili sonuçlar elde edilebilir.

5. KAYNAKLAR

- Adcock, A., Carlsson, E., & Carlsson, G. (2013). *The Ring of Algebraic Functions on Persistence Bar Codes* (arXiv:1304.0530). arXiv.
- Al-Jumaily, A., & Olivares, R. A. (2009). Electromyogram (EMG) driven system based virtual reality for prosthetic and rehabilitation devices. *Proceedings of the 11th International Conference on Information Integration and Web-based Applications & Services*, 582-586.
- Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A., & Aljaaf, A. J. (2020). A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science. İçinde M. W. Berry, A. Mohamed, & B. W. Yap (Ed.), *Supervised and Unsupervised Learning for Data Science* (ss. 3-21). Springer International Publishing.
- Anam, K., & Al-Jumaily, A. (2017). Evaluation of extreme learning machine for classification of individual and combined finger movements using electromyography on amputees and non-amputees. *Neural Networks*, 85, 51-68.
- Anil, N., & Sreeletha, S. H. (2018). EMG Based Gesture Recognition Using Machine Learning. *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, 1560-1564.
- Arivalagan, D., M, M., M, S. M., S, S. D., & O, V. (2024). Unveiling Alzheimer's Stages Through Transfer Learning and Custom CNN Layers. *2024 International Conference on Distributed Computing and Optimization Techniques (ICDCOT)*, 1-6.
- Arland, F., Setiawan, A. W., & Adzkia, M. (2023). *Multi-Feature Extraction EMG For Classification of Finger Movement*. 1-5.
- Asghar, A., Jawaid Khan, S., Azim, F., Shakeel, C. S., Hussain, A., & Niazi, I. K. (2022). Review on electromyography based intention for upper limb control using pattern recognition for human-machine interaction. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, 236(5), 628-645.
- Asghari Oskoei, M., & Hu, H. (2007). Myoelectric control systems—A survey. *Biomedical Signal Processing and Control*, 2(4), 275-294.
- Atkinson, J. (2018). *Computational modelling techniques to determine patellofemoral joint loads*.
- Bastian Grossenbacher-Rieck (Direktör). (2020, Eylül 15). *Topological Data Analysis for Machine Learning III: Topological Descriptors & How to Use Them*.

- Benalcázar, M. E., Jaramillo, A. G., Jonathan, Zea, A., Páez, A., & Andaluz, V. H. (2017). Hand gesture recognition using machine learning and the Myo armband. *2017 25th European Signal Processing Conference (EUSIPCO)*, 1040-1044.
- Bhardwaj, P., Kumar, S., & Kumar, Y. (2023). A Comprehensive Analysis of Deep Learning-Based Approaches for the Prediction of Gastrointestinal Diseases Using Multi-class Endoscopy Images. *Archives of Computational Methods in Engineering*, 30(7), 4499-4516.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). Training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, 144-152.
- Brownlee, J. (2016, Mart 15). Supervised and Unsupervised Machine Learning Algorithms. *MachineLearningMastery.Com*. <https://machinelearningmastery.com/supervised-and-unsupervised-machine-learning-algorithms/>
- Burrello, A., Morghet, F. B., Scherer, M., Benatti, S., Benini, L., Macii, E., Poncino, M., & Pagliari, D. J. (2022). *Bioformers: Embedding Transformers for Ultra-Low Power sEMG-based Gesture Recognition* (arXiv:2203.12932). arXiv.
- Chen, M., Bashford, J., & Zhou, P. (2022). Motor Unit Number Estimation (MUNE) Free of Electrical Stimulation or M Wave Recording: Feasibility and Challenges. *Frontiers in Aging Neuroscience*, 14, 799676.
- Chen, Z., Fan, G., Li, A., Yuan, J., & Xu, T. (2020). rAAV2-Retro Enables Extensive and High-Efficient Transduction of Lower Motor Neurons following Intramuscular Injection. *Molecular Therapy. Methods & Clinical Development*, 17, 21-33.
- Chung, E. A., & Benalcázar, M. E. (2019). Real-Time Hand Gesture Recognition Model Using Deep Learning Techniques and EMG Signals. *2019 27th European Signal Processing Conference (EUSIPCO)*, 1-5.
- Clancy, E. A., Morin, E. L., & Merletti, R. (2002). Sampling, noise-reduction and amplitude estimation issues in surface electromyography. *Journal of Electromyography and Kinesiology*, 12(1), 1-16.
- Côté-Allard, U., Fall, C. L., Drouin, A., Campeau-Lecours, A., Gosselin, C., Glette, K., Laviolette, F., & Gosselin, B. (2019). Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(4), 760-771.
- Devaraj, A., & Nair, A. K. (2020). Hand Gesture Signal Classification using Machine Learning. *Proceedings of the 2020 IEEE International Conference on Communication and Signal Processing, ICCSP 2020*, 390-394.
- Du, Y., Jin, W., Wei, W., Hu, Y., & Geng, W. (2017). Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation. *Sensors (Basel, Switzerland)*, 17(3).

- Fukano, K., Iizawa, K., Soeda, T., Shirai, A., & Capi, G. (2021). Deep Learning for Gesture Recognition based on Surface EMG Data. *International Conference on Advanced Mechatronic Systems, ICAMechS, 2021-December*, 41-45.
- Goceri, E. (2023). Comparison of the impacts of dermoscopy image augmentation methods on skin cancer classification and a new augmentation method with wavelet packets. *International Journal of Imaging Systems and Technology*, 33(5), 1727-1744.
- Guo, W., Yao, P., Sheng, X., Liu, H., & Zhu, X. (2014). A wireless wearable sEMG and NIRS acquisition system for an enhanced human-computer interface. *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics, 2014-January*(January), 2192-2197.
- Hamilton-Wright, A., & Stashuk, D. W. (2005). Physiologically based simulation of clinical EMG signals. *IEEE Transactions on Bio-Medical Engineering*, 52(2), 171-183.
- Han, Z., Tao, Q., Lai, Q., & Liu, L. (2021). Multi-gesture recognition method of single-channel EMG signal based on deep learning. *2021 International Conference on Cyber-Physical Social Intelligence, ICCSI 2021*.
- Hensel, F., Moor, M., & Rieck, B. (2021). A Survey of Topological Machine Learning Methods. *Frontiers in Artificial Intelligence*, 4.
- Hofer, C., Kwitt, R., Niethammer, M., & Uhl, A. (2018). *Deep Learning with Topological Signatures* (arXiv:1707.04041). arXiv.
- James, C. J., & Hesse, C. W. (2004). Independent component analysis for biomedical signals. *Physiological Measurement*, 26(1), R15.
- Jin, L., Zhang, Y., Wang, X.-L., Zhang, W.-J., Liu, Y.-H., & Jiang, Z. (2017). Postictal apnea as an important mechanism for SUDEP: A near-SUDEP with continuous EEG-ECG-EMG recording. *Journal of Clinical Neuroscience*, 43, 130-132.
- Karlsson, S., Yu, J., & Akay, M. (2000). Time-frequency analysis of myoelectric signals during dynamic contractions: A comparative study. *IEEE Transactions on Bio-Medical Engineering*, 47(2), 228-238.
- Kaya, G., & Ergin, G. (2021). Nörolojik Hastalıklarda Yorgunluk ve Değerlendirme Yöntemleri. *İzmir Katip Çelebi Üniversitesi Sağlık Bilimleri Fakültesi Dergisi*, 6(3), Article 3.
- Khezri, M., & Jahed, M. (2007). A novel approach to recognize hand movements via sEMG patterns. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference, 2007*, 4907-4910.
- Kleissen, R. F., Buurke, J. H., Harlaar, J., & Zilvold, G. (1998). Electromyography in the biomechanical analysis of human movement and its clinical application. *Gait & Posture*, 8(2), 143-158.

- Kundu, B. (2021). *Classification and Feature Extraction of Different Hand Movements from the EMG Signal Using Machine Learning based Algorithms* [M.S.E.E.]. <https://www.proquest.com/docview/2585943115/abstract/82F55AD9BF354FE4PQ/1>
- Leykam, D., & Angelakis, D. G. (2023). Topological data analysis and machine learning. *Advances in Physics: X*, 8(1), 2202331.
- Luca, C. J. D. (1997). The Use of Surface Electromyography in Biomechanics. *Journal of Applied Biomechanics*, 13(2), 135-163. <https://doi.org/10.1123/jab.13.2.135>
- Luo, Z., Ren, X., & Jia, Y. (2004). Multi-pattern recognition of the forearm movement based on SEMG. *International Conference on Information Acquisition, 2004. Proceedings.*, 369-371.
- Marchant, B. P. (2003). Time–frequency Analysis for Biosystems Engineering. *Biosystems Engineering*, 85(3), 261-281.
- Merlo, A., Bò, M. C., & Campanini, I. (2021). Electrode Size and Placement for Surface EMG Bipolar Detection from the Brachioradialis Muscle: A Scoping Review. *Sensors*, 21(21), Article 21.
- Mobarak, M. P., Guerrero, R. M., Gutiérrez Salgado, J. M., & Dorr, V. L. (2014). Hand movement classification using transient state analysis of surface multichannel EMG signal. *2014 Pan American Health Care Exchanges (PAHCE)*, 1-6.
- Nazari, F., Mohajer, N., Nahavandi, D., & Khosravi, A. (2022). Comparison of gait phase detection using traditional machine learning and deep learning techniques. *2022 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 403-408.
- Negi, S., Kumar, Y., & Mishra, V. M. (2016). Feature extraction and classification for EMG signals using linear discriminant analysis. *2016 2nd International Conference on Advances in Computing, Communication, & Automation (ICACCA) (Fall)*, 1-6.
- Obayashi, I., Nakamura, T., & Hiraoka, Y. (2022). Persistent Homology Analysis for Materials Research and Persistent Homology Software: HomCloud. *Journal of the Physical Society of Japan*, 91(9), 091013.
- Ozdemir, M. A., Kisa, D. H., Guren, O., Onan, A., & Akan, A. (2020). EMG based Hand Gesture Recognition using Deep Learning. *TIPTEKNO 2020 - Tip Teknolojileri Kongresi - 2020 Medical Technologies Congress, TIPTEKNO 2020*.
- Pekiştirmeli öğrenme. (2024). İçinde *Vikipedi*. https://tr.wikipedia.org/w/index.php?title=Peki%C5%9Ftirmeli_%C3%B6%C4%9Frenme&oldid=31138972
- Ravishanker, N., & Chen, R. (2021). An introduction to persistent homology for time series. *WIREs Computational Statistics*, 13(3), e1548.

- Rodríguez-Tapia, B., Soto, I., Martínez, D. M., & Arballo, N. C. (2020). Myoelectric Interfaces and Related Applications: Current State of EMG Signal Processing—A Systematic Review. *IEEE Access*, 8, 7792-7805.
- Seenaa, V., & Yomas, J. (2014). A review on feature extraction and denoising of ECG signal using wavelet transform. *2014 2nd International Conference on Devices, Circuits and Systems (ICDCS)*, 1-6.
- Sharma, S., Farooq, H., & Chahal, N. (2016). Feature Extraction and Classification of Surface EMG Signals for Robotic Hand Simulation. *Communications on Applied Electronics*, 4(2), 27-31.
- Shi, R., & Niu, L. (2020). A brief survey on Capsule Network. *2020 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT)*, 682-686.
- Shi, X., Zhai, M., Qin, P., Yu, K., & Zhou, W. (2021). A new sEMG signal feature extraction method based on S transform. *2021 IEEE International Conference on Real-time Computing and Robotics (RCAR)*, 1419-1424.
- Sisodia, P. S., Ameta, G. K., Kumar, Y., & Chaplot, N. (2023). A Review of Deep Transfer Learning Approaches for Class-Wise Prediction of Alzheimer's Disease Using MRI Images. *Archives of Computational Methods in Engineering*, 30(4), 2409-2429.
- Stockwell, R. G., Mansinha, L., & Lowe, R. P. (1996). Localization of the complex spectrum: The S transform. *IEEE Transactions on Signal Processing*, 44(4), 998-1001.
- Taylor, G. W., Sigal, L., Fleet, D. J., & Hinton, G. E. (2010). Dynamical binary latent variable models for 3D human pose tracking. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 631-638.
- Wang, X., Lin, X., & Dang, X. (2020). Supervised learning in spiking neural networks: A review of algorithms and evaluations. *Neural Networks*, 125, 258-280.
- Xiang, X., & Foo, S. (2021). Recent Advances in Deep Reinforcement Learning Applications for Solving Partially Observable Markov Decision Processes (POMDP) Problems: Part 1—Fundamentals and Applications in Games, Robotics and Natural Language Processing. *Machine Learning and Knowledge Extraction*, 3(3), Article 3.
- Yazıcı, İ. (2008). *EMG İşaretlerinin İşlenmesi Ve Sınıflandırılması* [Master's]. <https://www.proquest.com/docview/2689289416/abstract/EF5E0BA9100E4F53PQ/4>
- Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences*, 12(17), Article 17.
- Zawawi, T. N. S. T., Abdullah, A. R., Sudirman, R., Saad, N., & Mahmood, N. H. (2020). A Review of Electromyography Signal Analysis of Fatigue Muscle for Manual

Lifting. *2020 6th International Conference on Computing Engineering and Design (ICCED)*, 1-6.

Zecca, M., Micera, S., Carrozza, M. C., & Dario, P. (2002). Control of multifunctional prosthetic hands by processing the electromyographic signal. *Critical reviews in biomedical engineering*, 30(4-6), 459-485.

Zeebaree, D. Q., Hasan, D. A., Abdulazeez, A. M., Ahmed, F. Y. H., & Hasan, R. T. (2021). Machine Learning Semi-Supervised Algorithms for Gene Selection: A Review. *2021 IEEE 11th International Conference on System Engineering and Technology (ICSET)*, 165-170.

Zhang, J., Ling, C., & Li, S. (2019). Human movements classification using multi-channel surface EMG signals and deep learning technique. *Proceedings - 2019 International Conference on Cyberworlds, CW 2019*, 267-273.



ÖZGEÇMİŞ

İlk ve ortaokul eğitimini Trabzon'da tamamladı. Lise eğitimini 2015 yılında Rize Türkiye Odalar ve Borsalar Birliği Fen Lisesi'nde tamamladı. 2021 yılında Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nden mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Anabilim dalında tezli yüksek lisans programına başladı. Yaklaşık 2 senedir Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği Devreler ve Sistemler anabilim dalında Araştırma Görevlisi olarak görev yapmaktadır.

