

**T.C.  
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**BENZER EL HAREKETLERİNİN EMG SİNYALLERİ  
KULLANILARAK SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**Ayşe Dilan DERDİYOK**

**Enstitü Anabilim Dalı : BİYOMEDİKAL MÜHENDİSLİĞİ**

**Tez Danışmanı : Doç. Dr. Mustafa Zahid YILDIZ**

**Haziran 2021**

T.C.  
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BENZER EL HAREKETLERİNİN EMG SİNYALLERİ  
KULLANILARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Ayşe Dilan DERDİYOK

Enstitü Anabilim Dalı : BİYOMEDİKAL  
MÜHENDİSLİĞİ

**Bu tez 23/ 06/ 2021 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.**

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Doç.Dr. Mustafa Zahid YILDIZ	BAŞARILI
Üye: Doç. Dr. Emre DANDIL	BAŞARILI
Üye: Dr. Öğr. Üyesi Ayşe Nur AY	BAŞARILI

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Ayşe Dilan DERDİYOK

23.06.2021

## TEŐEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Mustafa Zahid YILDIZ'a teşekkürlerimi sunarım.

Akademik çalışmalarım sırasında, birçok aşamada beni destekleyen ve yardımcı olan birlikte çalışmaktan büyük keyif aldığım, tecrübeleriyle her zaman yoluma ışık tutan, saygıdeğer hocam Dr. Öğr. Üyesi Ayşe Nur AY'a büyük bir minnetle teşekkür ederim.

Hayatımın her sürecinde her daim yanımda olan ve destek veren aileme teşekkür ederim.

## İÇİNDEKİLER

BEYAN.....	i
TEŞEKKÜR .....	ii
İÇİNDEKİLER .....	iii
KISALTMALAR .....	v
SİMGELER .....	vi
TABLolar LİSTESİ.....	vii
ŞEKİLLER LİSTESİ.....	viii
ÖZET.....	ix
SUMMARY .....	x

### BÖLÜM 1.

GİRİŞ .....	1
1.1. Tezin Amacı .....	1
1.2. Literatür Araştırması .....	2

### BÖLÜM 2.

ELEKTROMYOGRAFI (EMG) .....	5
2.1. EMG Özellikleri ve Gürültü Kaynakları .....	7
2.2. EMG Sinyalinin Elde Edilmesinde Kullanılan Yöntemler .....	8
2.3. EMG Sinyalinin İşlenmesi .....	11
2.3.1. Sayısal örnekleme frekansı .....	11
2.3.2. EMG sinyalinin zaman domeninde incelenmesi .....	12
2.3.2.1. Doğrultma .....	12
2.3.2.2. Sinyalin yumuşatılması .....	14
2.3.2.3. Doğrultulmuş sinyalin ortalaması .....	14
2.3.2.4. Entegrasyon .....	15
2.3.2.5. RMS değerinin ölçülmesi .....	16
2.4. EMG Sinyalinden Özellik Çıkarılması .....	16
2.4.1. Dalga biçimi uzunluğu .....	16
2.4.2. Ortalama mutlak değer .....	16
2.4.3. Ortalama kök kareler .....	17
2.4.4. Kutozis .....	17
2.4.5. Sıfır geçiş .....	17
2.4.6. Willison genliği .....	17

2.4.7. Eğim işareti değişiklikleri .....	18
2.4.8. Entropi.....	18
2.4.9. Otoregresif model .....	18
2.4.10. Varyans .....	19
2.5. Emg Sinyallerin Sınıflandırılması.....	19
2.5.1. Makine öğrenmesi ve derin öğrenme.....	19
2.5.2. En yakın k-komşu algoritması (k-NN) .....	23
2.5.3. Destek vektör makineleri (SVM) .....	25
2.5.4. Topluluk öğrenimi (Ensemble learning).....	27
2.5.5. Karar ağaçları (Decision trees) .....	28
2.5.6. Lineer ayırtaç analizi (Linear discriminant analysis).....	29
2.6. Derin Öğrenme .....	29
2.6.1. Modelin tanımlanması.....	30
2.6.2. Derin öğrenme katmanları.....	30
2.6.3. Aktivasyon fonksiyonları.....	31
2.6.4. Giriş ve çıkış katmanları .....	31

### **BÖLÜM 3.**

<b>MATERYAL VE METOD.....</b>	<b>33</b>
3.1. Deneysel Çalışma.....	33
3.2. EMG Verilerinin Toplanması ve Katılımcı Bilgileri .....	34
3.3. Elde Edilen EMG Sinyallerinin İşlenmesi .....	36
3.4. EMG Sinyallerinin Sınıflandırılması .....	38
3.4.1. Karar ağaçları (Decision tree).....	38
3.4.2. Destek vektör makineleri (SVM).....	39
3.4.3. Toplu öğrenme (Ensemble learning).....	40
3.4.4. K-komşu algoritması (k-NN).....	41
3.4.5. Derin öğrenme.....	43

### **BÖLÜM 4.**

<b>SONUÇLAR VE TARTIŞMA .....</b>	<b>44</b>
-----------------------------------	-----------

### **BÖLÜM 5.**

<b>DEĞERLENDİRME .....</b>	<b>50</b>
----------------------------	-----------

<b>KAYNAKLAR .....</b>	<b>51</b>
------------------------	-----------

## KISALTMALAR

AR	: Autoregressive
CNN	: Convolution Neural Network
CRFs	: Conditional Random FieldsM
DSA	: Derin Sinir Ağları
EMG	: Elektromiyografi
GMMs	: Gaussian Mixture Models
H	: Entropy
KNN	: K-Nearest Neighbor
LDA	: Lineer Diskriminant Analizi
MAV	: Mean Absolute Value
MLP	: Multi Layer Perceptron
MMH	: Maximum Marginal Hyper
RELU	: Destek Vektör Makineleri
RMS	: Root Mean Square
RNN	: Recurrent Neural Network
ROC	: Receiver Operating Characteristic
S-CRC	: Spectral Collaborative Representation
SDK	: Software Development Kit
SSC	: Slope Sign Changes
SVD	: Singular Value Decomposition
SVM	: Destek Vektör Makineleri
SVM	: Support Vector Machine
TP	: Gerçek Pozitifler
WAMP	: Willison Amplitude
WL	: Waveform Length
YSA	: Yapay Sinir Ağları
ZC	: Zero Crossing

## SİMGELER

Hz	: Hertz
mV	: Milivolt
mV	: Milisaniye
T	: Peryot
$V_o, V_s$	: Dönüşüm Fonksiyonları
$m(t)$	: Sinyal Eğrisi
I	: Emg Sinyali
$t_j, t_i$	: Zaman Sınır Değerleri
$X(k)$	: Örnekleme Verileri Vektörü
N	: Vektör Uzunluğu
k	: Eğim İşareti
$\phi_i$	: Model Katsayıları
p	: AR model
obs/ sec	: Training time



## TABLolar LİSTESİ

Tablo 3.1 : Cinsiyet ve el hareketine göre toplanan örnek sayısı.....	35
Tablo 3.2 : Karar ağaçları özellikleri tablosu.....	39
Tablo 3.3 : Destek vektör makineleri özellikleri.....	40
Tablo 3.4 : Toplu öğrenme özellikleri. ....	40
Tablo 3.5 : k-NN sınıflandırma parametreleri.....	41
Tablo 3.6 : Derin öğrenme model eğitim özellikleri .....	43
Tablo 4.1 : Kullanılan sınıflandırma methodlarının tahmin doğruluk değerleri.....	44
Tablo 4.2 : Derin öğrenme kayıp ve doğruluk tahmini değerleri.....	49

## ŞEKİLLER LİSTESİ

Şekil 2.1 : Motor ünitenin yapısı.....	6
Şekil 2.2 : Motor üniteleri aksiyon potansiyelleri ve EMG sinyali oluşumu.....	6
Şekil 2.3 : EMG sinyaline ait frekans spektrumu .....	7
Şekil 2.4 : EMG sinyalinin tipik genlik karakteristiği .....	8
Şekil 2.5 : EMG düzeni blok diyagramı.....	9
Şekil 2.6 : İğne tipi elektrot.....	9
Şekil 2.7 : Yapışkan bantlı elektrot.....	10
Şekil 2.8 : Tipik bir EMG sinyali (sol) ve örneklenmiş EMG sinyali (sağ) .....	11
Şekil 2.9 : Yarım dalga doğrultucu uygulanan sinüzoidal eğri.....	13
Şekil 2.10 : Tam dalga doğrultucu uygulanan sinüzoidal eğri.....	13
Şekil 2.11 : Denetimli /Denetimsiz öğrenme metodlarının örnek gösterimleri .....	22
Şekil 2.12 : k-NN algoritması şekilsel gösterimi .....	24
Şekil 2.13 : Destek Vektör Makinesi. Destek Vektörleri, sadece gözlemin koordinatlarıdır. Destek Vektör Makinesi, iki sınıftan (hiper düzlem / çizgi) en iyi ayıran bir sınırdır. ....	26
Şekil 2.14 : Destek Vektör Makinelerinin çalışma şekli.....	27
Şekil 2.15 : Derin öğrenme ağ yapısı .....	31
Şekil 3.1 : Emg verilerinin sınıflandırılması için önerilen çalışmanın şeması.....	33
Şekil 3.2 : Kullanıcı tarafından yapılacak el hareketleri: (a) Silindir kavrama. (b) Küre kavrama. (c) Yumruk. (d) Hassas kavrama .....	34
Şekil 3.3 : Thalmic Myo Armband .....	36
Şekil 3.4 : İşlenmiş EMG sinyali çıktıları.....	37
Şekil 3.5 : Yumruk hareketi için EMG sinyal işlemenin sekiz sensör çıktı grafiği ...	38
Şekil 4.1 : Knn algoritması karışıklık matrisi tablosu.....	45
Şekil 4.2 : Knn algoritması ROC eğrisi .....	46
Şekil 4.3 : SVM algoritması karışıklık matrisi tablosu .....	47
Şekil 4.4 : SVM algoritması ROC eğrisi.....	47

# BENZER EL HAREKETLERİNİN EMG SİNYALLERİ KULLANILARAK SINIFLANDIRILMASI

## ÖZET

Rehabilitasyon cihazlarını destekleyen robotik sistemler son yıllarda oldukça gelişmiştir. El fonksiyonunu karşılayan robotik protezlerin de sürekli iyileşme arzusu nedeniyle bir kaza geçirdikten sonra elin kaybedilmesi, kas-sinir rahatsızlıkları ile bağlantılı fonksiyonunun kısmen ya da tamamen yitilmesi, iskelet cihazlarının geliştirilmesinde büyük rol oynamıştır. Yüzeysel elektromiyografi (sEMG) sinyallerinin kullanıldığı bu tür bir cihazlar, sağlıklı elin hareketlerini belirlemeye ve hasar görmüş eli yeniden fonksiyonel bir hale getirmeye yardımcı olabilmektedir. EMG sinyalleri ile protez kontrolünün gerçekleştirilmesi için sinyallerin özelliklerinin iyi bilinmesi gerekir. Bu özellikler sayesinde el hareketlerinin sınıflandırılması mümkün hale gelir. El hareketlerinin tanınması genellikle, bireysel hareket verilerini içeren jestsel örneklerin olduğu bir model sınıflandırma problemidir. Bu tez çalışmasında Myo TM Armbandı (Akıllı Kol Bant) tarafından elde edilmiş olan, yüzeysel elektromiyografik sinyallerinin benzer hareketleri ayırt etmede sınıflandırılması amaçlanmaktadır. Bu çalışmada kullandığım 225 katılımcıdan alınan ve benzer el hareketi yapılmış olan açık kaynak EMG veri setini, öncelikle ön işleme adımlarından geçirildikten sonra, özellik çıkarımı adımları gerçekleştirilmiştir. Çıkarılan Dalga Biçimi Uzunluğu (WL), Ortalama Mutlak Değer (MAV), Ortalama Kök Kareler (RMS), Basıklık (Kutozis), Sıfır Geçiş (ZC), Willison Amplitude (WAMP), Eğim İşareti Değişiklikleri (SSC), Entropi (H), Otoregresif model (AR), Varyans (VAR) özellikleri sınıflandırıcıya girdi olarak verilmiştir. Sınıflandırıcı olarak sırasıyla Karar ağaçları (Decision Trees), Destek vektör makineleri (SVM), Toplu Öğrenme (Ensemble learning), yakın K- en komşu algoritmaları (k-NN) denenmiş olup; bu algoritmalar içinde doğruluk başarısı diğer algoritmalara oranla %87.6 olarak en yüksek k- en yakın komşu algoritması ile elde edilmiştir. Böylece literatürde mevcut olan el hareketlerini ayırıştırma çalışmalarına kıyasla benzer el hareketlerinden elde edilen bu sinyallerle değerlendirilebilir bir başarı oranına ulaşılmıştır.

Anahtar Kelimeler: Elektromiyografi, Özellik Çıkarımı, Sınıflandırma, k-NN Algoritması, Sinyal İşleme

# **CLASSIFICATION OF SIMILAR HAND MOVEMENTS USING EMG SIGNALS**

## **SUMMARY**

Robot- assisted rehabilitation devices have developed considerably in recent years. Partial or complete loss of function associated with muscle-nerve disorders or loss of the hand after an accident played a major role in the development of robotic control devices or prosthetics. Such devices, using surface electromyography (sEMG) signals, can help identify the movements of the healthy hand and re-functionalize the impaired hand.

In order to control the prosthesis with EMG signals, the characteristics of the signals must be well known. Thanks to these signal features, it becomes possible to classify hand movements. Recognition of hand gestures is generally a model classification problem with gestural samples containing individual and distinct movement data.

In this thesis, a new algorithm is presented for the classification of surface electromyographic signals obtained by the Myo TM Armband. After preprocessing the EMG data obtained from experiments based on 4 different hand movements with 225 participants, feature extraction steps were performed. Extracted Waveform Length (WL), Mean Absolute Value (MAV), Mean Root Squares (RMS), Kurtosis (Cutosis), Zero Crossing (ZC), Willison Amplitude (WAMP), Slope Sign Changes (SSC), Entropy (H) , Autoregressive model (AR), Variance (VAR) features are given as input to the classifier. Decision trees (Decision Trees), Support vector machines (SVM), Ensemble learning, close k-nearest neighbors algorithms (k-NN) were tried respectively as classifiers; The highest accuracy rate of 87.6% was obtained with the k-NN algorithm. Thus, a very high success rate has been achieved with these signals obtained from movements that are very close to each other compared to the hand gesture recognition studies available in the literature.

**Keywords:** Electromyography, Feature Extraction, Classification, k-NN Algorithm, Signal Processing

## **BÖLÜM 1. GİRİŞ**

Günümüzde Elektromiyografi (EMG) sinyalleri kullanılarak yapay uzuv ve rehabilitasyon ile ilgili birçok çalışma yapılmaktadır. Bu tez çalışmasında da bu alana katkı sağlamak amacıyla çeşitli el hareketlerine bağlı olarak açık erişimli bir EMG veri setinden alınmış olan sinyaller farklı yöntemlerle sınıflandırılmış ve sınıflandırma başarıları kıyaslanmıştır. Tez ile ilgili literatür çalışmaları bu bölümde ayrı ayrı başlıklar altında verilmiştir.

### **1.1. Tezin Amacı**

EMG, kas işaretlerinin ölçümünde kullanılan medikal bir yöntemdir. Kas hareketleri sırasında oluşan bu EMG sinyallerinin kas ve sinir rahatsızlığı tedavilerinde, fizik tedavi rehabilitasyon uygulamalarında ve protez sistemlerin geliştirilmesinde kaynak sinyal olarak kullanılmaktadır (A. Chaudhary, 2018). Son dönemde bu alanlarda yapılan çalışmalar rehabilitasyon görevlerini destekleyen robotik sistemlerin gelişimi önemli ölçüde artmıştır. Protez el mekaniklerinin sürekli iyileştirme arzusu nedeniyle, bir yaralanma geçirdikten sonra, dış iskelet cihazlarının geliştirilmesine büyük çaba harcanmıştır. Bu cihazlar, en yaygın aktif terapi veya pasif terapi olmak üzere, farklı rehabilitasyon uygulamalarında kullanılmıştır. Bu çalışma ile günlük hayatta kullanılan el hareketleri ile EMG sinyallerinin sınıflandırılma performansı artırılarak biyonik el geliştirme çalışmalarına ve rehabilitasyon ekipmanlarına katkı sağlamak amaçlanmıştır. Sınıflandırma başarısının artırılması klinik uygulamalarda kas hastalıklarının tespitine ve protez organ geliştirme başarısındaki artışa dolaylı olarak katkı sağlayacak gelişmeleri de beraberinde getirecektir. Bunu yapmak için, ölçülen sinyallerin ne şekilde sınıflandırılacağını tanımlamak gerekir. El hareketleri genellikle hem bireysel hem de benzer hareketler olduğundan ve hareket verilerini içeren jestsel örnekler olduğundan, bu bir model sınıflandırma problemi olur. El hareketlerinin tanınmasında kullanılan en bilinen sınıflandırıcılar arasında k-NN Yakın Komşu

(kNN), Destek Vektör Makineleri (SVM), Yapay Nöronal Ağlar (YSA), Derin Evrişimli Ağlar (DNN) bulunur. EMG sinyallerinin ölçülmesi için literatürde birkaç yöntem bulunmaktadır.

## 1.2. Literatür Araştırması

EMG sinyallerinin alınıp işlenmesi ve bu sinyallerden sonuç çıkarılması protez kol çalışmaları ve kas ve sinir rahatsızlığı tedavilerinin tespiti için gerekmektedir. Günümüzde akıllı sistemlerin gelişmesinin sonucu olarak EMG tabanlı protezler ve EMG sinyallerinden hastalık tespiti çalışmaları önemli ölçüde artmıştır. EMG sinyalinin ölçülmesi ve kaydedilmesi, EMG sinyalinden özellik çıkarılması ve seçilen bu özelliklerin sınıflandırılması bu çalışmaların temelini oluşturmaktadır. Bu kapsamda literatüre birçok çalışma kazandırılmıştır. Bu çalışmalardan bazıları aşağıda özetlenmiştir.

Wannous ve diğerleri (2008) protez elleri kontrol etmek için altı el hareketini sınıflandırmak için destek vektör makinesi (SVM) yöntemini kullanmıştır. Sınıflandırma doğruluğu yaklaşık %88 çıkmıştır (Wannous et al., 2008).

Oskoei ve Hu (2008), sınıflandırma için SVM kullanılan diğer bir çalışmada, EMG sinyallerini kullanarak üst ekstremitte hareketlerinin SVM yöntemi sınıflandırmasını kullanmışlardır. Dört farklı çekirdeği analiz etmişler ve sonuçlar, sınıflar arasındaki sınırların pratikte doğrusal olduğunu göstermiştir. Araştırmacılar son zamanlarda Sinir Ağları ile sınıflandırmaya da odaklanmışlardır (M. A. Oskoei and H. Hu, 2008).

A. Prof ve arkadaşları (2014) yaptığı çalışmada EMG sinyallerinden MÜAP ve Otoregresif (AR) modeli ile öznitelik çıkartılmıştır. Çıkarılan bu öznitelikler geri besleme sinir ağı ile sınıflandırıldığında %88, Radyal Temel fonksiyonu sinir ağı ile sınıflandırıldığında %89.33 ortalama başarıyı elde etmiştir (A. Prof, 2014).

Khushaba ve arkadaşları (2012) “Yüzey elektromiyogram sinyalleriyle protez parmakların gelişmiş kontrolü” adlı çalışmalarında 2 kanal elektrot kullanarak parmak hareketlerinin sınıflandırılması üzerinde çalışmış, öznitelik yöntemi olarak zaman bölgesi özniteliklerinin yanı sıra özbağlanım katsayılarını da kullanmış, sınıflandırma yöntemi olarak da Destek Vektör Makinesi ve kNN algoritmalarıyla 10 farklı hareketin

sınıflandırılmasını sağlamışlar, elde ettikleri sonuçları karşılaştırmışlardır (Khushaba, R. N., Kodagoda, S., Tavruri, M., Dissanayake, 2012).

Gürkan KÜÇÜKYILDIZ vd. (2015) yaptıkları çalışmada, engelliler için bir tekerlekli sandalyenin otomatik kontrolü ön kola takılan EMG bileklik (Myo Armband) ve Kinect sensör kullanılarak gerçekleştirilmiştir. EMG sensöründen elde edilen veriler kablosuz haberleşme (bluetooth) kullanılarak bilgisayara aktarılmış ve MATLAB ortamında işlenmiştir (Küçükyıldız, G., Ocak, H., Şayli, Ö., ve Karakaya, 2015).

Lucas vd. (2008) yaptıkları çalışmada miyoelektrik protezleri kontrol amacı ile çok kanallı EMG işaretlerinin danışmanlı sınıflandırılması için bir yöntem önermektedir. EMG işaretinin Ayrık Dalgacık dönüşümünün üzerine temellendirilmiştir. Çok kanallı çözüm kümesinde SVM algoritmasıyla sınıflandırma gerçekleştirmiş kolun üzerindeki 8 bölgeden kaydedilen EMG ile 6 el hareketinin sınıflandırılmasında uygulanmıştır (Lucas, M.F., Gaufriau, A., Pascual, S., Doncarli, C., Farina, 2008).

Rabin ve diğerleri (2020) tarafından yapılan çalışmada EMG sınıflandırmasında doğrusal olmayan boyutluluk ile standart doğrusal boyutluluk yöntemi arasındaki farkın analiz edilmesi amaçlanmıştır. Kısa Süreli Fourier Dönüşümü, 6-farklı el hareketini sınıflandırmak için EMG sinyaline özellik çıkarımı için uygulanmıştır. Boyut indirgeme temel bileşen analizi ve kullanılan difüzyon haritaları ve sınıflandırıcı için seçilen K-en yakın komşular. Sonuçlar, sınırlı eğitim verilerinde Temel Bileşen Analizi'nin DM'den daha düşük başarıya sahip olduğunu göstermiştir (N. Rabin, M. Kahlon, S. Malayev, 2020).

Ahmad, S.A., Chappell (2007) tarafından yapılan çalışmada 20 denekten aldıkları bilek hareketleri yaptıkları esnada izometrik kasılma ve tepki kasılma EMG sinyalleri yüzey elektrotlar ile kaydedilmiş ve bu veriler sınıflandırılmıştır (S. A. Ahmad and P. H. Chappell, 2007).

Arief, Z., Sulistijono, I. A., ve Ardiansyah, (2015) yaptıkları çalışmada Myo Arbandı ile zaman domenindeki özelliklerden 5 tanesi ile başarı sonuçlarını tablolarla karşılaştırmışlardır. Ve bu yaptıkları çalışmalar sonucunda EMG sinyalleri için MAV ve WL'nin en yüksek doğruluğa sahip zaman alanı sınıflandırılması olarak önerilmektedir (Arief, Z., Sulistijono, I. A., ve Ardiansyah, 2015).

Güvenç tarafından (2014) yapılmış olan tez çalışmasında, yapay uzuvların fonksiyonlu olabilmesi amacıyla yaptığı çalışma farklı el ve kol hareketlerine ait EMG sinyalleri işlenerek hareketlerin sınıflandırılması yapılmıştır. Bu çalışmada 8 bireyin kolundan alınan yüzey EMG sinyalleri işlenerek 7 farklı hareket sınıfının ayrıştırılması sorunu YSA ile çözümlenmiştir. Çalışmanın amacı, örüntü tanıma tabanlı kontrol hakimiyetine sahip aktif protez tasarımı klinik uygulamalarına katkı sağlamaktır (Güvenç, 2014).






## **BÖLÜM 2. ELEKTROMİYOGRAFİ (EMG)**

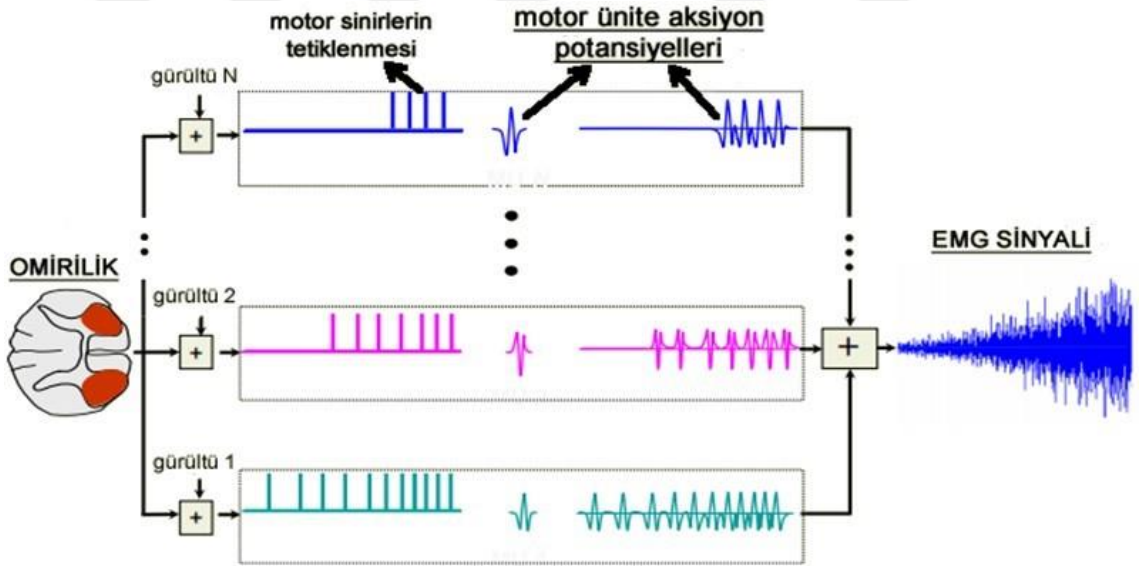
Elektromiyografi (EMG), iskelet kaslarından yayılan elektrik sinyallerinin tespiti, analizi ve kullanımı ile ilgilenen konudur (Castellini, C., van der Smagt, P., Sandini, G. ve Hirzinger, 2008). Bu elektriksel sinyaller kas hücrelerimizin kasılıp gevşemesiyle ortaya çıkan ve miyoelektrik olarak adlandırılan işaretlerdir. Sinyallerin kaynağı vücuttaki çeşitli elektrokimyasal olaylardır (Şenli, 2011). EMG sinyali ölçmüş olduğu kasın nöromusküler aktivesiyle ilgili bilgi vermektedir (Çerçi, Çağrı ,Hakan Temeltaş, 2017).

Bedenin temel taşı olan hücrelerimizin içinde ve dışında süregelen bir iyon dengesi bulunmaktadır. İstemli hareket durumunda beynin motor korteks bölgesinde uyarılabilme özelliğinde olan nöron hücrelerimizin iyon dengesindeki değişim sunucunda hücrelerde aksiyon potansiyeli (AP) adı verilen elektriksel potansiyel oluşur. Birbiriyle bağlantı içerisinde olan sinir hücrelerinin bu şekilde tetiklenmesi ile uyarı, omurilik üzerinden hedef kas bölgesine kadar iletilmiş olur. Bu uyarının taşınması motor sinirler vasıtasıyla gerçekleşir ve motor sinirinin son kısmı, kasları oluşturan yüzlerce kas lifinden bağlanarak liflerin kasılma ve gevşemesini sağlar. Motor sinirinin son ucu ile kas liflerinin bağlantı oluşturduğu yapıya motor ünite denir (Özyener, 2014). Farklı motor ünitelerinin kasa bağlı yapısal formu Şekil 2.1 'de görülmektedir (Dr. Carlo J. De Luca", 2014; Güvenç, 2014).



Şekil 2.1 : Motor ünitenin yapısı

Bir kasın çalışmasında değişen oranda motor ünite görev alır. Motor ünitelerin sayısı, kasın fonksiyonuna göre farklılık gösterir. Şekil 2.2’de bir kasın kasılması devam etmesi için oluşturdukları aksiyon potansiyelleri ve bu potansiyellerin toplamından ham EMG sinyalinin oluşum şekli gösterilir. (Dr. Carlo J. De Luca“, 2014; Güvenç, 2014)



Şekil 2.2 : Motor üniteleri aksiyon potansiyelleri ve EMG sinyali oluşumu


EMG işaretlerinin elektriksel özellikleri incelenirse genliğinin mikro voltlar seviyesinde olduğu görülür değeri ise alınan kişinin cinsiyetine, kasın türüne ve yaşına bağlı olarak değişiklik gösterir.

EMG sinyalinin frekans bandı 10-500 Hertz (Hz) arasında olup, baskın frekans değeri 30-150 Hz' dir. Alınan kullanıma uygun sinyaller, elektriksel gürültü düzeyinin üstünde enerji taşımaktadırlar. EMG sinyalleri elektrotlar aracılığıyla algılanmakta ve bu elektrotların çeşidine göre farklı isimlerle adlandırılmaktadırlar (Şenli, 2011). Günümüzde Elektromiyografi sinyalleri tıbbi rehabilitasyon robotları, insan makine arayüzü, biyomedikal araştırmalar gibi çalışma alanlarında kullanılmaktadır (Zhang, Y., Liu, B., Ji, X., & Huang, 2001). Bilgisayar teknolojisinin gelişmesiyle EMG hayatı kolaylaştırma noktasında önemli olmaktadır.

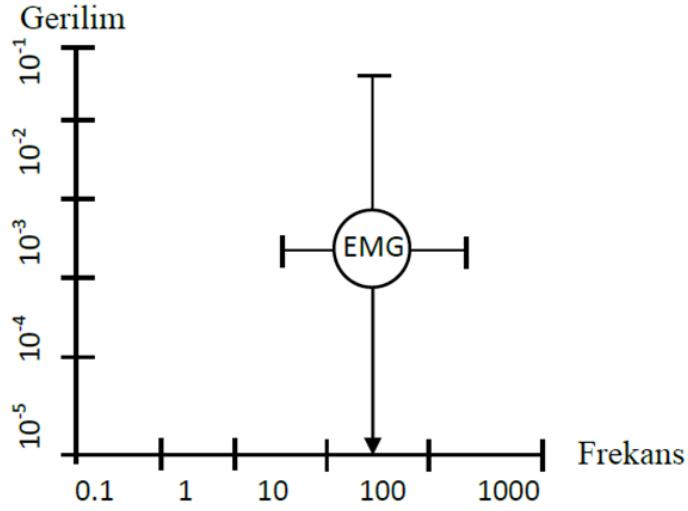
EMG sinyallerinin kullanılmasıyla bu sinyaller değişik amaçlar doğrultusunda sınıflandırılmaktadır . Bu sınıflama türleri incelendiğinde el hareketlerinin (Zhang, Y., Liu, B., Ji, X., & Huang, 2001), parmak hareketlerinin (Çalışkan, 2019), vücut pozisyonu belirlemeni (Jaramillo-Yáñez et al., 2020) çalışıldığı görülmektedir. EMG sinyallerinin hastalıkların tespiti (Çalışkan, 2019) ya da protez el/kol yapımında da (Chan vd., 2000; Bağcı, 2016; Engin,Taşan ve Engin, 2015) karşımıza çıktığı görülmektedir.

## 2.1. EMG Özellikleri ve Gürültü Kaynakları

EMG sinyali rastlantısal forma sahiptir ve Gaussian dağılım fonksiyonuyla tanımlanmaktadır. EMG işaretlerinin genlikleri 0 ile 10 mV (tepe noktaları arası) arasında değişir. Şekil 2.3 'de EMG sinyalinin frekans spektrumu ve Şekil 2.4' de EMG sinyaline ait genlik karakteristiği grafiği görülmektedir (K., 2007; "Webster, John G., 1978, Medical Instrumentation, Applications and Design," 1978).



Şekil 2.3 : EMG sinyaline ait frekans spektrumu

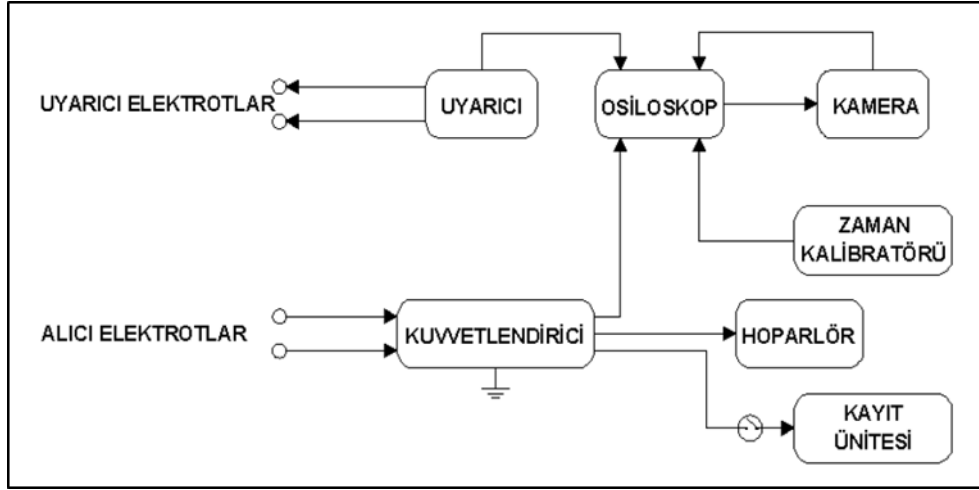


Şekil 2.4 : EMG sinyalinin tipik genlik karakteristiği

Kullanılabilecek olan sinyal enerjisi 50 ile 500 Hz frekans aralığında hakim olan enerji 50 ile 150 Hz arasında değişmektedir. Alınan kullanıma uygun sinyaller, elektriksel gürültü düzeyinin üstünde enerji taşımaktadırlar (Ejderha, H., 2009).

## 2.2. EMG sinyalinin elde edilmesinde kullanılan yöntemler


Kliniklerde kullanılan EMG ölçüm düzenekleri, EMG işaretlerini tespit etmeye yardımcı olan elektrotlar, uyarıcı, kuvvetlendirici, osiloskop, magnetik kaydedici ve hoparlör gibi cihazlardan oluşur. İnceleme amaçlı yapılan çalışmalar için bunların haricinde, spektrum analizörleri, işaret işleme blokları ve bilgisayar da bulunabilir. Uyarın aracılığıyla incelenecek olan kasın motor siniri uyarılarak kas liflerindeki elektromiyogram sinyalleri, alıcı elektrotlar yardımıyla biyopotansiyel kuvvetlendiriciye ve görüntüleme ünitesine aktarılır. EMG düzeni uygulama aşamasında ve taşımada kolaylık sağlaması açısından kompakt ünite olarak veya kas işaretleri dışındaki biyopotansiyelleri de ölçebilecek nitelikte genel olarak gerçekleştirilirler. Şekil 2.5’de EMG sinyallerinin elde edilmesi amacıyla kullanılan sistemin blok diyagramı görülmektedir (Özmen, 2013).



Şekil 2.5 : EMG düzeni blok diyagramı


Biyolojik işaretleri toplamak amacıyla elektrot çeşitleri tasarlanmıştır. Biyoelektrotlar, iyonik iletkenliği elektronik iletkenliğe dönüştürmesiyle elektronik devrelerde işlenebilir duruma getirmeyi sağlayan bir tür sensördür. Biyoelektrotlardaki amaç Elektromiyogram (EMG) ve diğer medikal açıdan önemli biyoelektriksel sinyalleri alabilmektir. Bu elektrotlar iğne elektrotlardır ve yüzey elektrotlar (Güler, 2015).

İğne elektrotlar: İğne elektrotları veya kas içi tel elektrotları, yüzey elektrotlarına göre tercih edilir. Çünkü bunlar, tek tek motor ünitelerine girebilir ve gelen aksiyon potansiyellerini daha kesin olarak değerlendirebilirler. En yaygın kullanılan iğne elektrot, tek kutuplu tek elektrotlu eş merkezli halka iğnedir. Diğer iğne elektrotları, tek lifli EMG (sFEMG) ve makro-EMG (Togawa, T., Tamura, T. ve Oberg, 1997) tarafından kullanılır. İğne elektrotlardan farklı olarak tel elektrotlar daha basit bir şekilde bükülür ve kinesiyojji çalışmaları için kullanılır. Şekil 2.6'da iğne tipi elektrot modeli gösterilmiştir (Güler, 2015).



Şekil 2,6: İğne tipi elektrot

Yüzey elektrotları: Bu elektrotlar EMG işaretlerinin ölçümü, tespiti amacıyla invazif olmayan bir teknik sağlar. Bu elektrotların kullanım prensipleri elektrolitik iletim yoluyla tespit yüzeyi ile cilt arasında kimyasal bir denge oluşturmalarıdır, bu sayede akım elektroda akabilir. Bu yöntemle EMG sinyallerinin alınması kolaydır ancak; sadece kas dokusunun üst bölgesi hakkında veri alınır kas dokusunun alt kısımları hakkında bilgi edinilemez. Aktif yüzey elektrotları yüzeyindeki yükselteç devresiyle ölçüm alınan yerdeki işareti belirli bir kat yükseltir. Pasif elektrotlar ise herhangi bir devreye sahip olmadığı için işaret alındığında yükseltme yapılmaz (Konard, 2012). Burada hedef motor ünite aktivitelerini yakından incelemek ve hastalık için doğru teşhisi koyabilmektir. Ölçüm yapılacak olan bölgenin üst yüzeyine yapıştırılan elektrot ile birlikte yükseltme işlemi yapılacak olan birime alınan işaretler aktarılır. Bu elektrotlar basittir ve uygulaması çok kolaydır. İğne ve ince tel elektrotların uygulanması, sıkı tıbbi gözetim ve sertifika gerektirir. Yüzey EMG elektrotları böyle bir formalite gerektirmese de yüzey elektrotlarının da bazı sınırlamaları vardır (Masso, N., Rey, F., Romero, D., Gual, G., Costa, L. ve German, 2010). Bu elektrotlar cilde uygulandığı için genellikle sadece yüzeysel kaslar için kullanılırlar. Diğer kasların karışması büyük bir sorundur. Deri ile şekli sabit tutulması gerekir; aksi takdirde sinyal bozulur. Şekil 2.7’de Yapışkan bantlı elektrot şekli verilmiştir (Güler, 2015).




Şekil 2.7 : Yapışkan bantlı elektrot

### 2.3. EMG Sinyalinin İşlenmesi

EMG sinyallerinden, doğruluğu ve EMG sinyallerinden işlenebilir anlamlı bilgiler elde edilmek isteniyorsa, ham EMG sinyallerinin bir işlem sürecinden geçirilmesi gerekmektedir. Ham EMG sinyali bozulmadan uygulanan bu işlemlerin tümüne sinyal işleme methodları denilmektedir. Sinyal işleme methodlarının hedefi sinyali kullanılabilir ve analiz edilebilir şekile dönüştürmektir. EMG sinyallerini işleme sırasında yapılan methodlar sinyalin davranışını ve özelliklerini değiştirmemesi için özen gösterilmelidir. Bu şekilde, elde edilen sinyal verileri, bu kısımda anlatılan sırayla sinyal işleme adımlarından geçerek sınıflandırma için hazır hale getirilmiştir.

#### 2.3.1. Sayısal örnekleme frekansı

Sinyaller sürekli zamanlı sinyaller ve ayrık zamanlı sinyaller olarak iki gruba ayrılmaktadır. Ayrık zamanlı sinyaller dijital, sürekli zamanlı sinyaller analog sinyaller, olarak adlandırılır. Dijital sinyaller veriyi ayrı, analog sinyaller ise verileri sürekli değişen formda göstermektedir. Alınan EMG sinyallerinin de analog sinyaller gibi elektronik sistemlerde değerlendirilebilmesi için, bu sinyallerin sayısal seriler ile ifade edilmesi gerekmektedir. Yüze EMG sinyalleri sayısallaştırılması aşamasında, alınan sinyaller belirli bir örnekleme oranında, bilgisayar sistemi aracılığıyla analog sinyalden dijital sinyale (A / D) dönüştürücü ile dönüştürülmektedir ve analog EMG sinyali “örneklenmiş” sinyale dönüştürülmüş olur. Şekil 2.8’de analog bir EMG sinyali ve örneklenmiş dijital şekli görülmektedir.



Şekil 2.8 : Tipik bir EMG sinyali (sol) ve örneklenmiş EMG sinyali (sağ).

Örnekleme frekansı, sinyallerin sayısal duruma dönüştürülmesi olarak tanımlanır. Sinyal işleme metodu için örnekleme frekansı seçimine dikkat edilmelidir; yüksek frekans seçilmesi durumunda sinyal, gürültü sinyali içerir veya düşük bir frekans

hatalara sebep olabilir (Sadhukhan et al., 1994). Sinüzoidal formdaki sinyal, tekrar ve bozulma olmaksızın elde edilebilmesi için kullanılması gereken minimum düzeyde örnekleme frekansı değerine Nyquist frekansı denir. Örnekleme işlemini anlatan teorem de Nyquist teoremi olarak adlandırılmaktadır.

Nyquist teoreminde işaretin örnekleme frekansı, büyüklüğü ne düzeyde olursa, orijinal sinyale benzerliği de o kadar artar. Nyquist teoremine göre, benzerliğin olması ve minimum düzeylerde bozulmaların gerçekleşmesi için, seçili olan örnekleme frekansının kullanılan en yüksek frekans değerinin en az iki katı olmalıdır. Rastgele bir sinyal olan EMG sinyali karmaşık bir yapıda olduğundan kastaki özelliklerin alınıp iletilmesi için, yüksek frekans değerinde örnekleme yapılması gerekmektedir.

### **2.3.2. EMG sinyalinin zaman domeninde incelenmesi**

EMG sinyal işleme için zaman etki alanında çeşitli analizler yapılmaktadır. Bu sinyal işleme adımlarından bu bölümde bahsedilecektir. Bu adımlar, RMS, doğrultma, ortalama alma, alçak geçiren filtreleme, entegrasyon, değerinin ölçülmesidir.

#### **2.3.2.1. Doğrultma**

Ön işleme yöntemi olan sinyalin doğrultması (rectification) işlemi, EMG ile ölçülen sinyaller ile uygunluğun belirlenmesine imkân tanır (L.J Myers ve diğerleri, 2003). Ham EMG sinyalini tek bir sinyale dönüştürür. Yarım dalga doğrultma ve tam dalga doğrultma olarak farklı türde sinyal doğrultma yöntemi vardır. EMG sinyalini işleme aşamasında sadece pozitif değerleri analiz edilir. Yarım dalga doğrultma yapılırken, negatif veriler gider ve pozitif veriler elde tutulur. Doğrultma işleminde genellikle, enerjinin tümünü kullanılabilmesi için tam dalga doğrultma biçiminde yapılır. Bunun sonucunda doğrultulan işaret, ham işaretin mutlak değerini gösterir. Yarım dalga doğrultmada negatif girişler sıfırlanırken, tam dalga doğrultma işlemi, negatif girdileri pozitif yapan doğrultmadır (Reaz MB, Hussain MS, 2006).


Yarım-dalga doğrultucu dönüşüm fonksiyonu:

$$V_o = \begin{cases} 0 & \text{ için } V_s < 0 \\ V_s & \text{ için } V_s > 0 \end{cases} \quad (2.1)$$



$V_o$  ise çıkış fonksiyonunu iken,  $V_s$  transfer (dönüşüm) fonksiyonunu gösterir.

Yarım dalga doğrultucunun çıkışı Şekil 2.9'daki gibi olacaktır (Rahime Yılmaz & Arslan, 2017).




Şekil 2,9 : Yarım dalga doğrultucu uygulanan sinüzoidal eğri.

Tam-dalga doğrultucu için dönüşüm fonksiyonu:

$$\begin{cases} -V_s & \text{ için } V_s < 0 \\ V_s & \text{ için } V_s > 0 \end{cases} \quad (2.2)$$

Tam dalga doğrultucunun çıkışı Şekil 2.10'daki gibi olur (Rahime Yılmaz & Arslan, 2017).



Şekil 2.10: Tam dalga doğrultucu uygulanan sinüzoidal eğri.

### 2.3.2.2. Sinyalin yumuřatılması

EMG sinyallerinde motor ünitelerinin deęiřimi (motor ünite apına ve aksiyon potansiyelinin akıřmasına baęlı olarak) sebebiyle rasgele bir formdadır. Doęrultma uygulanmıř sinyalin rasgele genlięi ile ilgili bilgi edinmek iin kullanılan ynteme yumuřatma (smoothing) denir. Sinyalin yumuřatılması, alınan motor ünitelerin devamlı deęiřmesiyle (motor ünitelerinin ap ve motor ünitesi aksiyon potansiyellerinde ki akıřmanın rastgele olmasına baęlı olarak) EMG sinyali yapısal formu rastgele niteliktedir (Konard, 2012). Doęrultma iřlemi uygulanan sinyal, sinyalin genlięini gsterir. EMG iřaretinden genlik hakkında bilgi edinmek amacıyla kullandığımız bu ynteme yumuřatma (smoothing) denir. EMG sinyalini yumuřatma iřlemi adımımda, iřarete mevcut olan yksek frekanslı bileřen dalgaların (high-frequency fluctuations) sinyalden ıkarılmasıyla ile gerekleřtirilir. Bylece sinyal daha przsz grnr. Yumuřatma, iřaretin alak geiren filtreden (low pass filter) geirilmesi olarakta ifade edilmektedir. İřarete yapılan yumuřatma dzeyi, kullanılan filtrenin bant geniřlięine baęlıdır; Bant geniřlięi miktarı bu iřlemdede etken bir maddededir, miktar ne derece kkse yumuřatma da o dzeyde byk olur (C. J. Basmajian, J.V. ve de Luca, 1985).

### 2.3.2.3. Doęrultulmuř sinyalin ortalaması

Bir iřaretin ortalamasının alınması demek, matematiksel olarak yumuřatma iřlemi uygulandıęı anlamına gelir.

T uzunluęundaki bir  $m(t)$  sinyalinin ortalaması;

$$\overline{m(t)} \Big|_{t_j - t_i} = \frac{1}{t_i - t_j} \int_{t_j}^{t_i} m(t) dt \quad (2.3)$$

matematiksel ifade ile hesaplanır (C. J. (1985). Basmajian, J.V. ve de Luca, n.d.). Burada  $t_j$  ve  $t_i$ , sinyalin sahip olduęu integrasyonun zaman sınır deęerlerini ifade eder. Yukarıdaki ifadedede,  $T = t_j - t_i$  zaman aralıęındaki iřaretin ortalamasını hesaplamamızı saęlar. Sinyalin, zamana baęlı ortalamasının hesaplanması istenmesi durumunda, iřaret T uzunluęunda pencere ile gzden geirilerek ilerleme saęlanır ve bu pencereye dahil olan her iřaret aralıęının ortalaması alınmaktadır. Ve bu ortalamanın deęeri:

$$|\overline{m(t)}| = \frac{1}{T} \int_t^{t+T} |m(t)| dt \quad (2.4)$$

Denklem formülü ile hesaplanır (C. J. Basmajian, J.V. ve de Luca, 1985). Literatür taramasında yapılan çalışmalarda T değeri 100 ms ile 200 ms aralığında seçilir (C. J. Basmajian, J.V. ve de Luca, 1985).

#### 2.3.2.4. Entegrasyon

Tümleştirme (Integration), fonksiyon denklem eğrisinin altında kalan alanın hesaplanması işlemidir. Ham EMG sinyali rastgele sinyaller olduğundan, sinyal eğrisinin altında kalan alan eğer ortalama değeri 0 ise hesaplanması sonucu (tümleştirilirse) elde edilen değer sıfır olur. Bu sebeple, tümleştirme adımı sadece tam dalga doğrultma işleminden sonra elde edilen sinyal üzerinde yapılır. Çıkarılan parametre birimleri V.s veya mV.ms.'dir. Sayısal olarak entegrasyon işlemi;

$$I\{|m(t)|\} = \int_0^t |m(t)| dt \quad (2.5)$$

denklemleriyle ifade edilir (C. J. Basmajian, J.V. ve de Luca, 1985) . Denklemde ki I bir EMG sinyalini, t zamanı, m(t) sinyal eğrisini ifade etmektedir. Entegrasyon yapılmış bir EMG işareti, girişin büyüklüğüne cevap niteliğinde çıkış oranının arttırarak bir periyot üzerindeki aktivitenin göstergesini verir. Entegrasyon işleminde, doğrultulmuş sinyal ile işlem yapılmasını gerektirdiğinden, doğrultma yapılmış sinyal çıkışı pozitif değer almaktadır. Doğrultma yapılmış değer pozitif olasıdan dolayı, doğrultma işlemi yapılmış işaretin tümleştirilmiş hali pozitif olur bununla birlikte zamanın bir fonksiyonu şeklinde devamlı artma göstererek devam eder. Doğrultulmuş sinyalin ortalama ile doğrultulmuş sinyalin tümleştirme farkı ortalama alınırken doğrultulma yapılmış işaret değerinin ortalamanın üzerinde T zamanına bölünmesidir (C. J. Basmajian, J.V. ve de Luca, 1985). Doğrultulmuş işaretin ortalama karşılığı, doğrultulmuş işaretin entegrasyon değeri vb. işaretin zamanla bağımlı olan farklılıklarını gösterir bunun sayesinde, sinyal sınıflandırma uygulamalarında kullanılmak amacıyla yarar sağlayacak bilgiler bulunmaktadır. Bu işlem;

$$I\{|m(t)|\} = \int_t^{t+T} |m(t)| dt \quad (2.6)$$

denklemleri ile elde edilir.

### 2.3.2.5. RMS değerinin ölçülmesi

Sinüs, kare gibi dalga şeklinde ki sinyallerin genlik ve RMS değeri arasındaki bağıntı biliniyor. Bu sebeple bu özelliğe ki işaretlerle güç hesaplarında, sinyallerin genlik değerleri kullanılabilir. EMG sinyali rastgele özellikte bir işaret olmasından dolayı genlik ve RMS değeri arasında bağıntı bulunmamaktadır. Bu sebeple bu tarzdaki işaretlerin kapsadığı gücün bulunabilmesi için RMS değerinin hesaplanması gereklidir.

Bu tez çalışmasında işlenen Ham EMG sinyali amaca yönelik sınıflandırma yapılabilmesi için çeşitli özniteliklerinin çıkarılması gerekir. Buradan hareketle bir sonraki başlıkta bu çalışmada kullandığımız öznitelikler verilmiştir.

## 2.4. EMG Sinyalinden Özellik Çıkarılması

Her bir sensörün sEMG sinyalleri için çıkarılan özellikler aşağıda belirtilmiştir, burada her bir özellik için  $X(k)$  vektördeki  $k$  örnekleme verilerini ve  $N$ , veri vektörünün uzunluğudur (Hudgins, B., Parker, P., and Scott, 1993).

### 2.4.1. Dalga biçimi uzunluğu

Dalga Biçimi Uzunluğu (WL), sEMG sinyalindeki değişim derecesini gösterebilen sEMG'nin kümülatif bir varyasyonudur (Joshi, D., Kandpal, K. ve Anand, 2008). Denklem 1.7'de ile tanımlanır.

$$WL = \frac{1}{N} \sum_{i=1}^N |X_i|^2 \quad (2.7)$$

### 2.4.2. Ortalama mutlak değer

Ortalama Mutlak Değer (MAV), EMG işaretinin mutlak değerinin ortalaması alınarak hesaplanan tam dalga düzeltilmiş sEMG sinyalinin ortalaması kullanılarak hesaplanabilir. Kas kasılma seviyelerini tespit etmenin kolay bir yoludur ve miyoelektrik kontrol uygulamasında kullanılan popüler bir özelliktir (Phinyomark, A., Limsakul, C. ve Phukpattaranont, 2009). Denklem 1.8'deki gibi tanımlanır.

$$VAM = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (2.8)$$

### 2.4.3. Ortalama kök kareler

Ortalama Kök Kareler (RMS), sinyalin ortalama değeridir (Phinyomark, A., Limsakul, C. ve Phukpattaranont, 2009). Denklem 1.9 ile hesaplanabilir.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2} \quad (2.9)$$

### 2.4.4. Kutozis

Basıklık, zaman serisi ölçümlerinin anlık genlikleri ile ilişkili olasılık dağılımının maksimum noktasını gösterir ve sinyalin frekans olasılığının bir özelliğidir (Wang, Y., Xiang, J., Markert, R. ve Liang, 2016). Tanım Denklem 1.10 'da verilmiştir.

$$Kurtosis = \frac{E((x-\mu)^4)}{\sigma^4} \quad (2.10)$$

### 2.4.5. Sıfır geçiş

Sıfır Geçiş (ZC), sinyalin sıfır genlik ekseninden geçme sayısıdır. Bu parametre, frekans alanındaki (Huang, H.-P. ve Chen, 1999) yaklaşık özelliği elde etmek için kullanılır. İki bitişik sEMG sinyali verildiğinde, EMG (k) ve EMG (k + 1), ZC Denklem 1.11 ile hesaplanabilir.

$$ZC = \sum_{k=1}^N \text{sgn}(f(x)) \quad (2.11)$$

$$\text{sgn}(x) = \begin{cases} 1 & \text{if } (X_k > 0 \text{ y } X_{k+1} < 0) \\ 0 & \text{if } (X_k < 0 \text{ y } X_{k+1} > 0) \\ & \text{Otherwise} \end{cases}$$

### 2.4.6. Willison genliği

Willison Amplitude (WAMP), sinyal genliğinin önceden tanımlanmış bir eşiği aşma sayısını saymak için kullanılan bir parametredir ve kas kasılma seviyesinin bir göstergesidir (Huang, H.-P. ve Chen, 1999). Şu şekilde yazılabilir.

$$WAMP = \sum_{k=1}^{N-1} f(|X_i - X_{i+1}|) \quad (2.12)$$

$$f(x) = \begin{cases} 1, & \text{if } x > \text{threshold} \\ 0, & \text{Otherwise} \end{cases}$$

#### 2.4.7. Eğim işareti değişiklikleri

Eğim İşareti Değişiklikleri (SSC), sinyalin eğiminin işaretini kaç kez değiştirdiğini sayar. Üç bitişik sEMG sinyali EMG (k - 1), EMG (k) ve EMG (k + 1) verildiğinde, eğim işaretinin sayısı değişir (Joshi, D., Kandpal, K. ve Anand, 2008). Şu şekilde yazılabilir.

$$SSC = \sum_{k=1}^{N-1} f(x) \quad (2.13)$$

$$f(x) = \begin{cases} 1, & \text{if } (X_k < X_{k+1}) \vee (X_k < X_{k-1}) \\ & \vee (X_k > X_{k+1}) \vee (X_k > X_{k-1}) \\ 0, & \text{Otherwise} \end{cases}$$

#### 2.4.8. Entropi

Entropi (H), ayrık bir rastgele değişken X'in belirsizliğini ölçer. Şu şekilde yazılabilir:

$$H(X) = -\sum_{x_i \in X} P(x_i) \log(P(x_i)) \quad (2.14)$$

#### 2.4.9. Otoregresif model

Otoregresif model (AR), bir zaman sinyalinin gözlem değerini, aynı serinin onun öncesinde olan belirli sayıda devrede gözlem değerinin ve hata fonksiyonunun doğrusal olarak bir gösteren modeldir. AR modelleri buldukları geçmiş gözlem değerleri sayısına göre isimlendirilirler. AR modeli genellikle şu şekilde ifade edilir:  $y(t)$  modellenecek zaman serisidir,  $\phi_i$  model katsayılarıdır,  $\varepsilon_t$  önceki noktalardan bağımsız beyaz gürültüdür ve parametre  $p$  AR modelinin sırasındır. AR (p) ile gösterilen bir  $p$  düzen AR modeli, mevcut gözlemin  $p$  geçmiş gözlemlere bağlı olduğunu gösterir. AR modelinin sırası, performansı değerlendirmek için önemli bir parametredir (Zhang et al., 2017).

$$y(t) = \sum_{i=1}^p \phi_i y(t-i) + \varepsilon_t \quad (2.15)$$

#### 2.4.10. Varyans

EMG sinyalinin varyansı, sinyalin gücünü ifade etmeye yarayan bir ölçüsüdür. X sinyalinde mevcut olan N örnek uzunluğundaki i segmenti ( $X_i$ ) içerisinde;  $x_k$ ,  $X_i$  segmentinin ortalamasını,  $x_k$  bir örneği göstermek için varyans özelliğinin matematiksel gösterim şekli denklem 1.16'da ifade edilmiştir (Zardoshti-Kermani, M., 1995).

$$VAR = \sigma^2 = \frac{1}{N} \sum_{k=1}^N (x_k - \bar{X}_i)^2 \quad (2.16)$$

#### 2.5. Emg Sinyallerin Sınıflandırılması

Bu çalışmada çıkarılan öznitelikler makine öğrenmesi ve derin öğrenme gibi algoritmalar aracılığıyla istenilen özelliklerin sınıflandırılması için kullanılabilir.

##### 2.5.1. Makine öğrenmesi ve derin öğrenme

Makine öğrenimi, insanların öğrenme şeklini taklit etmek için veri ve algoritmaların kullanımına odaklanan ve doğruluğunu kademeli olarak artıran bir yapay zeka (AI) ve bilgisayar bilimi dalıdır. Makine öğrenimi, büyüyen veri bilimi alanının önemli bir bileşenidir. İstatistiksel yöntemlerin kullanımı yoluyla, algoritmalar, veri madenciliği projelerindeki önemli içgörülerini ortaya çıkararak sınıflandırmalar veya tahminler yapmak için eğitilir. Bu içgörüler daha sonra uygulamalar ve işletmelerde karar verme sürecini yönlendirir ve ideal olarak temel büyüme metriklerini etkiler. Büyük veri genişlemeye ve büyümeye devam ettikçe, veri bilimciler için pazar talebi artacak ve en alakalı iş sorularının ve ardından bunları yanıtlayacak verilerin belirlenmesine yardımcı olmalarını gerektirecektir (Tygar, 2011).

Derin öğrenme ve makine öğrenimi birbirinin yerine kullanılma eğiliminde olduğundan, ikisi arasındaki nüanslara da dikkat çekmek gerekmektedir. Makine öğrenimi, derin öğrenme ve sinir ağları, yapay zekanın tüm alt alanlarıdır. Bununla birlikte, derin öğrenme aslında makine öğreniminin bir alt alanıdır ve sinir ağları, derin öğrenmenin bir alt alanıdır. Derin öğrenmenin ve makine öğreniminin farklı olma şekli, her algoritmanın nasıl öğrendiğidir. Derin öğrenme, sürecin özellik çıkarma parçasının çoğunu otomatikleştirerek, gerekli olan manuel insan müdahalesinin bir kısmını ortadan kaldırır ve daha büyük veri kümelerinin kullanılmasını sağlar.

Lex Fridman'ın belirttiği gibi derin öğrenmeyi “ölçeklenebilir makine öğrenimi” olarak düşünebilirsiniz. Klasik veya derin olmayan makine öğrenimi, öğrenmeye daha çok insan müdahalesine bağlıdır. İnsan uzmanlar, veri girişleri arasındaki farkları anlamak için bir dizi özelliği belirler ve genellikle öğrenmek için daha yapılandırılmış veriler gerektirir (Tsinganos et al., 2018).

Derin makine öğrenimi, algoritmasını bilgilendirmek için denetimli öğrenme olarak da bilinen etiketli veri kümelerinden yararlanabilir, ancak mutlaka etiketli bir veri kümesi gerektirmez. Yapılandırılmamış verileri ham haliyle (ör. Metin, görüntüler) alabilir ve farklı veri kategorilerini birbirinden ayıran özellikleri otomatik olarak belirleyebilir. Makine öğreniminin aksine, verileri işlemek için insan müdahalesi gerektirmez, bu da makine öğrenimini daha ilginç şekillerde ölçeklendirmemize olanak tanır. Derin öğrenme ve sinir ağları, öncelikle bilgisayarla görme, doğal dil işleme ve konuşma tanıma gibi alanlarda hızlanan ilerlemeyle tanınır.

Sinir ağları veya yapay sinir ağları, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı içeren bir düğüm katmanından oluşur. Her düğüm veya yapay nöron diğerine bağlanır ve ilişkili bir ağırlık ve eşik değerine sahiptir. Herhangi bir düğümün çıktısı belirtilen eşik değerinin üzerindeyse, o düğüm etkinleştirilerek ağına bir sonraki katmanına veri gönderilir. Aksi takdirde, ağına bir sonraki katmanına hiçbir veri aktarılmaz. Derin öğrenmedeki "derin", yalnızca bir sinir ağındaki katmanların derinliğine atıfta bulunur. Üçten fazla katmandan oluşan ve girdileri ve çıktıları içeren bir sinir ağı, bir derin öğrenme algoritması veya derin bir sinir ağı olarak düşünülebilir. Yalnızca iki veya üç katmana sahip bir sinir ağı, yalnızca temel bir sinir ağıdır.

UC Berkeley bir makine öğrenimi algoritmasının öğrenme sistemini üç ana bölüme ayırır (Tygar, 2011).

- **Bir Karar Süreci:** Genel olarak, bir tahmin veya sınıflandırma yapmak için makine öğrenimi algoritmaları kullanılır. Algoritmanız, etiketlenebilen veya etiketlenemeyen bazı girdi verilerine dayanarak, verilerdeki bir model hakkında bir tahmin üretecektir.
- **Bir Hata Fonksiyonu:** Bir hata fonksiyonu, modelin tahminini değerlendirmeye yarar. Bilinen örnekler varsa, bir hata fonksiyonu modelin doğruluğunu değerlendirmek için bir karşılaştırma yapabilir.



- **Bir Model Optimizasyon Süreci:** Model, eğitim setindeki veri noktalarına daha iyi uyabilirse, bilinen örnek ile model tahmini arasındaki tutarsızlığı azaltmak için ağırlıklar ayarlanır. Algoritma, bir doğruluk eşiğine ulaşılan kadar ağırlıkları otonom olarak güncelleyerek bu değerlendirme ve optimize etme sürecini tekrarlayacaktır.

Makine öğrenimi üç ana kategoriye ayrılmaktadır.

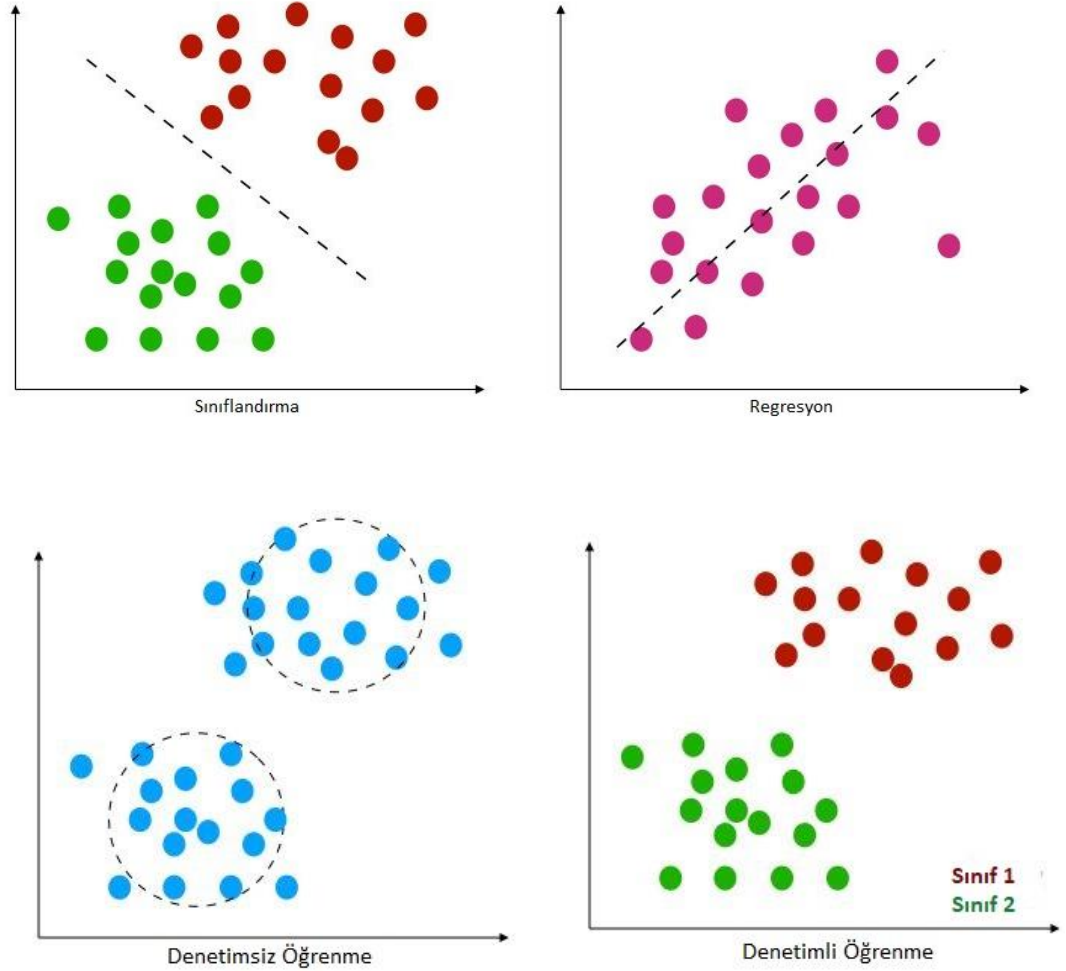
- **Denetimli makine öğrenimi:** Denetimli makine öğrenimi olarak da bilinen denetimli öğrenme, verileri sınıflandıran veya sonuçları doğru bir şekilde tahmin eden algoritmaları eğitmek için etiketli veri kümelerini kullanmasıyla tanımlanır. Girdi verileri modele beslendikçe, model uygun şekilde takılana kadar ağırlıklarını ayarlar. Bu, modelin gereğinden fazla veya yetersiz uyumdan kaçınmasını sağlamak için çapraz doğrulama sürecinin bir parçası olarak gerçekleşir. Denetimli öğrenme, kuruluşların, istenmeyen postayı gelen kutunuzdan ayrı bir klasörde sınıflandırmak gibi çeşitli gerçek dünya sorunlarını geniş ölçekte çözmelerine yardımcı olur. Denetimli öğrenmede kullanılan bazı yöntemler arasında sinir ağları, naif bölmeler, doğrusal regresyon, lojistik regresyon, rastgele orman, destek vektör makinesi (SVM) ve daha fazlası bulunur.

- **Denetimsiz makine öğrenimi:** Denetimsiz makine öğrenimi olarak da bilinen denetimsiz öğrenme, etiketlenmemiş veri kümelerini analiz etmek ve kümelemek için makine öğrenimi algoritmalarını kullanır. Bu algoritmalar, insan müdahalesine gerek kalmadan gizli kalıpları veya veri gruplamalarını keşfeder. Bilgilerdeki benzerlikleri ve farklılıkları keşfetme yeteneği, onu keşif amaçlı veri analizi, çapraz satış stratejileri, müşteri segmentasyonu, görüntü ve model tanıma için ideal çözüm haline getirir. Aynı zamanda boyutluluk azaltma süreciyle bir modeldeki özelliklerin sayısını azaltmak için de kullanılır; temel bileşen analizi ve tekil değer ayrışımı (SVD) bunun için iki yaygın yaklaşımdır. Denetimsiz öğrenmede kullanılan diğer algoritmalar arasında sinir ağları, k-ortalama kümeleme, olasılıksal kümeleme yöntemleri ve daha fazlası bulunur.

- **Yarı denetimli öğrenme:** Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme arasında mutlu bir ortam sunar. Eğitim sırasında, daha büyük, etiketlenmemiş bir veri kümesinden sınıflandırma ve özellik çıkarma işlemlerine rehberlik etmek için

daha küçük etiketli bir veri kümesi kullanır. Yarı denetimli öğrenme, denetimli bir öğrenme algoritması eğitmek için yeterli etiketli veriye sahip olmama (veya yeterli veriye etiketleyememe) sorununu çözebilir.

Güçlendirmeli makine öğrenimi, denetimli öğrenmeye benzer davranışsal bir makine öğrenimi modelidir, ancak algoritma veriler kullanılarak eğitilmemiştir. Bu model, deneme yanılma yöntemini kullanarak ilerledikçe öğrenir (Karla Dhungana Sainju, Niti Mishra, Akosua Kuffour, 2021) . Belirli bir sorun için en iyi öneriyi veya politikayı geliştirmek için bir dizi başarılı sonuç pekiştirilecektir. Şekil de denetimli ve denetimsiz öğrenme methodları görülür. Aşağıda Şekil 2.11'de Denetimli /Denetimsiz öğrenme methodlarının örnek gösterimleri verilmiştir (Github, 2020).



Şekil 2.11: Denetimli /Denetimsiz öğrenme methodlarının örnek gösterimleri

## 2.5.2. En yakın K-komşu algoritması (k-NN)

En yakın K-komşu algoritması, denetimli öğrenme tekniğine dayanan makine öğrenmesi algoritmalarından biridir. k-NN algoritması yeni vaka / veriler ile mevcut vakalar arasındaki benzerliği varsayar ve yeni vakayı mevcut kategorilere en çok benzeyen kategoriye koyar. Bu algoritma, mevcut tüm verileri depolar ve benzerliğe göre yeni bir veri noktasını sınıflandırır.

Bu, yeni veriler ortaya çıktığında k-NN algoritması kullanılarak kolayca bir kuyu grubu kategorisine sınıflandırılabilir anlamına gelir. k-NN algoritması, Regresyon için olduğu kadar Sınıflandırma için de kullanılabilir, ancak çoğu kez Sınıflandırma problemleri için kullanılır. k-NN parametrik olmayan bir algoritmadır, yani temeldeki veriler üzerinde herhangi bir varsayımda bulunmaz. Aynı zamanda kolay yapılandırmaya yönelik algoritma olarak da adlandırılır çünkü eğitim setinden hemen öğrenmez, bunun yerine veri setini depolar ve sınıflandırma sırasında veri setinde bir eylem gerçekleştirir. Eğitim aşamasındaki k-NN algoritması sadece veri setini depolar ve yeni veri aldığı anda bu verileri yeni verilere çok benzeyen bir kategori altında sınıflandırır.

Bu sistem, test verisini sınıflandırmak için, sistemin eğitim verilerinin en yakın olan k adet komşuyu bulur, sınıf elemanlarını yüklemek için en yakın komşuların kategorilerini kullanır (H., 1999). Bu sistem, sınıflandırmaları yapabilmek için k, en yakın komşular algoritması uzaklık işlevlerini kullanır. Bu sınıflandırma aşağıdaki uzaklık fonksiyonlarını kullanarak hesaplanabilir;

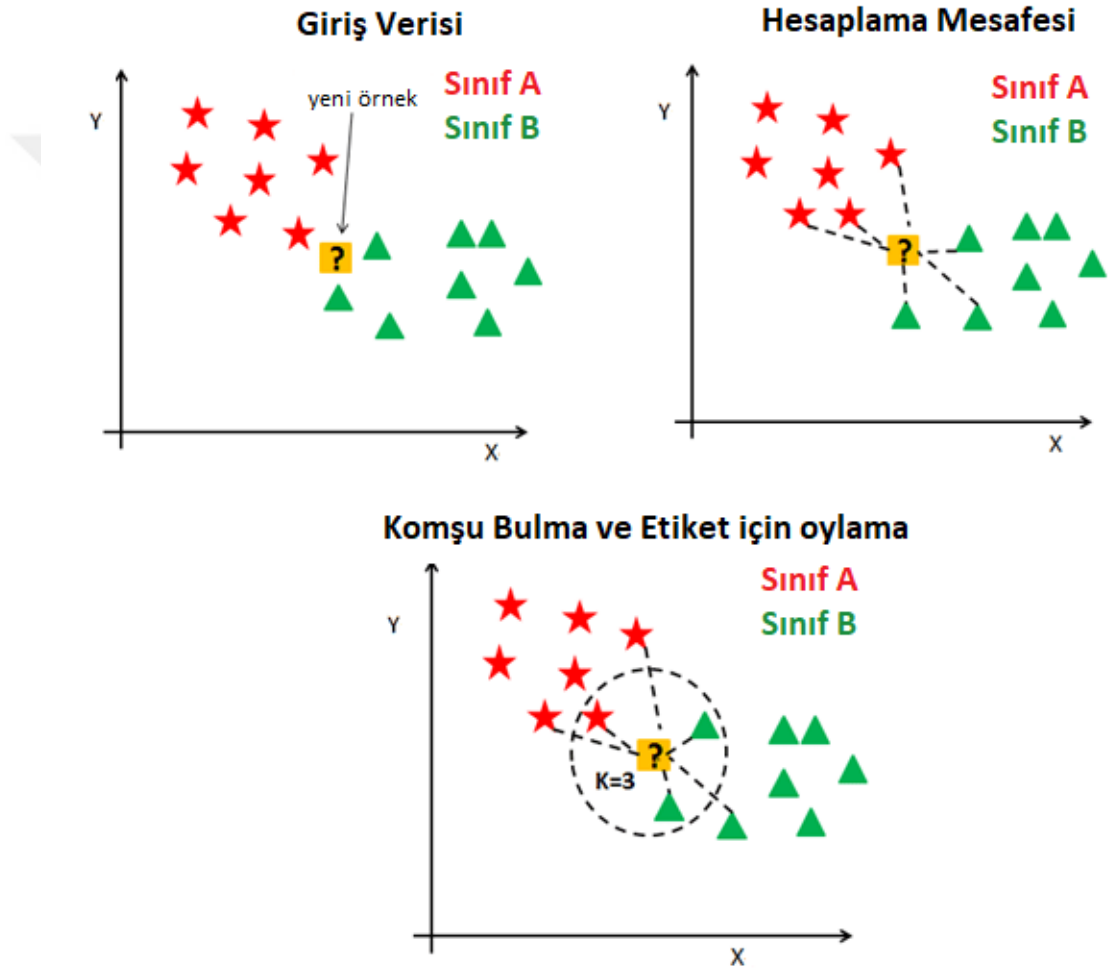
$$\text{Öklid Fonksiyonu} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2,17)$$

$$\text{Manhattan Fonksiyonu} = \sum_{i=1}^k |x_i - y_i| \quad (2,18)$$

$$\text{Minkowski Fonksiyonu} = (\sum_{i=1}^k (|x_i - y_i|^q))^{1/q} \quad (2,19)$$

Denklemlerde gösterilen uzaklık fonksiyonları, tez bütününde, sinyallerin işlenmesiyle oluşturulan öznitelik matrisinde, işaretin Eğitim değişikliği, Ortalama kök kareler, Kutozis, Varyans, Dalga biçimi uzunluğu, Ortalama mutlak değer Sıfır geçiş, Wilson genliği, Otoresif model, Entropy vb. özellikleri kullanır.

Test edilmek istenen işaretin sınıfını öğrenmek için öznitelik çıkarımı yapıldıktan sonra ve hangi sınıfa tabi olduğu bilinebilen sinyaller ile kıyaslanabilir. Bu kıyaslamalar aralarında uzaklıklara önem verilerek yapılır. Uzaklık ölçümü denklemi 4,1’de gösterilmiştir bu Öklid yöntemi kullanılarak hesaplanmıştır. Sonuç olarak test edilen işarete en yakın mesafeye sahip işaret hangi hareket grubu içerisinde ise, test sinyali de aynı grup içerisine dahil edilir. Şekil 2.12’de k-NN algoritması şekilsel gösterimi görülmektedir.



Şekil 2.12: k-NN algoritması şekilsel gösterimi.

Verimi en yüksek sonuçlar almak için en yakın seçilen komşu sayısı artırılabilir. Örnek olarak Şekil 2.12’de, sinyale en yakın dört komşu bileşenin dikkate alınmış olduğu görülmektedir. Bir sonraki aşamada bu dört komşu arasında çoğunluk seçimi yapıp, en doğru sonuçların elde edilmesine katkı sağlanabilecektir.

Elde edilen tecrübeler ışığında k-NN algoritmasının avantajları şunlardır:

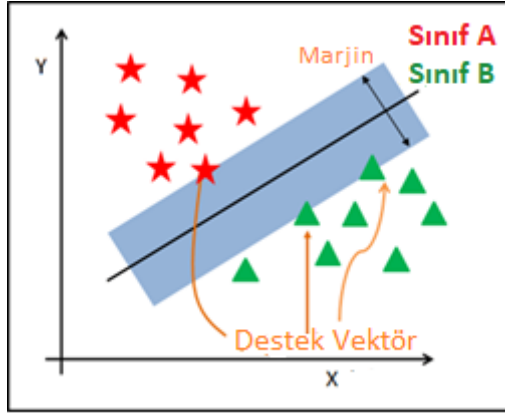
- Uygulaması basittir.
- Gürültülü eğitim verilerine karşı sağlamdır
- Eğitim verileri büyükse daha etkili olabilir.

k-NN algoritmasının dezavantajları ise şunlardır:

- Her zaman bir süre karmaşık olabilecek K'nin değerini belirlemesi gerekir.
- Tüm eğitim örnekleri için veri noktaları arasındaki mesafenin hesaplanması nedeniyle hesaplama maliyeti yüksektir.

### **2.5.3. Destek vektör makineleri (SVM)**

Destek vektör makinesi (SVM), iki gruplu sınıflandırma problemleri için sınıflandırma algoritmaları kullanan denetimli bir makine öğrenme modelidir. SVM, lojistik regresyon ve karar ağaçları gibi diğer sınıflandırıcılara kıyasla çok yüksek doğruluk sunar. Doğrusal olmayan girdi alanlarını işlemeye yönelik çekirdek hilesi ile bilinir. SVM algoritmasında kavramlar nispeten basittir. Sınıflandırıcı, veri noktalarını en büyük marj miktarına sahip bir hiper düzlem kullanarak ayırır. Bu nedenle, bir SVM sınıflandırıcı, ayırt edici sınıflandırıcı olarak da bilinir. SVM, yeni veri noktalarının sınıflandırılmasına yardımcı olan optimal bir hiper düzlem bulur. Genel olarak, Destek Vektör Makineleri bir sınıflandırma yaklaşımı olarak kabul edilir, ancak hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Birden çok sürekli ve kategorik değişkeni kolayca işleyebilir. SVM, farklı sınıfları ayırmak için çok boyutlu uzayda bir hiper düzlem oluşturur. SVM, bir hatayı en aza indirmek için kullanılan yinelemeli bir şekilde optimum hiper düzlem oluşturur. SVM'nin temel fikri, veri kümesini sınıflara en iyi şekilde bölen bir maksimum Marjinal Hiper Düzlem (MMH) bulmaktır (Navlani, 2019). Şekil 2.13'de Destek Vektör Makinesi, Destek Vektörleri, sadece gözlemin koordinatları ve Destek Vektör Makinesi, iki sınıftan (hiper düzlem / çizgi) en iyi ayıran bir sınırı gösterilmektedir (Navlani, 2019).

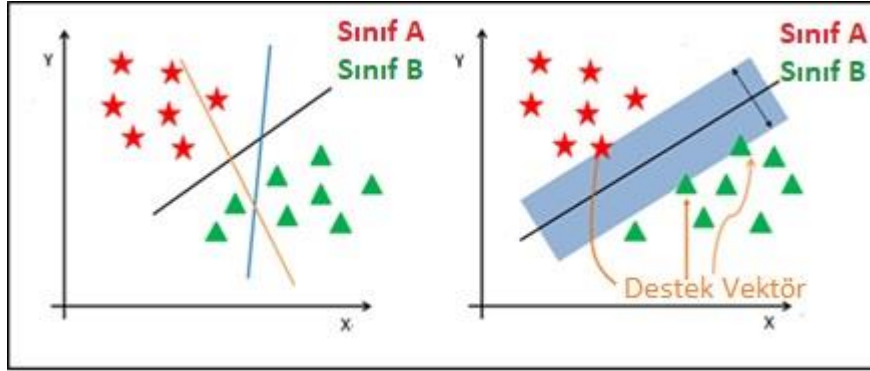


Şekil 2.13 : Destek Vektör Makinesi. Destek Vektörleri, sadece gözlemin koordinatlarıdır. Destek Vektör Makinesi, iki sınıftan (hiper düzlem / çizgi) en iyi ayıran bir sınırdır.

- **Destek Vektörleri:** Destek vektörleri, hiper düzleme en yakın olan veri noktalarıdır. Bu noktalar, kenar boşluklarını hesaplayarak ayırma çizgisini daha iyi tanımlayacaktır. Bu noktalar, sınıflandırıcının yapısı ile daha ilgilidir.
- **Hiper düzlem:** Bir hiper düzlem, farklı sınıf üyeliklerine sahip bir dizi nesneyi birbirinden ayıran bir karar düzlemidir.
- **Marj:** Bir kenar boşluğu, en yakın sınıf noktalarındaki iki çizgi arasındaki boşluktur. Bu, vektörleri veya en yakın noktaları desteklemek için çizgiden dikey mesafe olarak hesaplanır. Marj sınıflar arasında daha büyükse, iyi bir marj olarak kabul edilir, daha küçük bir marj kötü bir marjdır.

Temel amaç, verilen veri setini mümkün olan en iyi şekilde ayırmaktır. En yakın noktalar arasındaki mesafe, kenar boşluğu olarak bilinir. Amaç, verilen veri kümesindeki destek vektörleri içinde mümkün olan maksimum marjı olan bir hiper düzlem seçmektir. SVM, aşağıdaki adımlarda maksimum marjinal hiper düzlemi arar:

- Sınıfları en iyi şekilde ayıran hiper düzlemler oluşturun. Sol taraftaki şekil siyah, mavi ve turuncu üç hiper düzlemi gösteriyor. Burada mavi ve turuncunun daha yüksek sınıflandırma hatası var, ancak siyah iki sınıfı doğru şekilde ayırmaktadır.
- Sağ taraftaki şekilde gösterildiği gibi en yakın veri noktalarından maksimum ayırma sahip sağ alt düzlemi seçin. Şekil 2.14'de Destek Vektör Makinelerinin çalışma şekli gösterilmektedir (Navlani, 2019).



Şekil 2.14. Destek Vektör makinelerinin çalışma şekli.

Elde edilen tecrübeler ışığında destek vektör makinelerinin avantajları şunlardır:

- Sınıflar arasında net bir ayırım marjı olduğunda nispeten iyi çalışır.
- Yüksek boyutlu alanlarda daha etkilidir.
- Boyut sayısının örnek sayısından fazla olabildiği durumlar için etkilidir.
- Nispeten bellek verimlidir.

Destek vektör makinelerinin Dezavantajları ise şunlardır:

- SVM algoritması, büyük veri kümelerinde kullanım için uygun değildir.
- SVM, veri kümesinde daha fazla gürültü olduğunda, yani hedef sınıflar örtüşüğünde çok iyi performans göstermez.
- Her veri noktası için özellik sayısının eğitim veri örneği sayısını aştığı durumlarda, SVM düşük performans gösterecektir.
- Destek vektörü sınıflandırıcı, sınıflandırma hiper düzleminin üstüne ve altına veri noktaları koyarak çalıştığından, sınıflandırma için olasılıklı bir açıklama yoktur.

#### 2.5.4. Topluluk öğrenimi (ensemble learning)

Topluluk öğrenimi, iki veya daha fazla modelden gelen tahminleri birleştiren bir makine öğrenimi modelidir. Topluluk üyeleri olarak adlandırılan topluluğa katkıda bulunan modeller aynı tipte veya farklı tiplerde olabilir ve aynı eğitim verileri üzerinde eğitilebilir veya eğitilmeyebilir. Topluluk üyeleri tarafından yapılan tahminler, mod

veya ortalama gibi istatistikler kullanılarak veya her bir üyeye ne kadar ve hangi koşullar altında güvenileceğini öğrenen daha karmaşık yöntemlerle birleştirilebilir.

Topluluk yöntemlerinin incelenmesine 1990'larda başlanmış ve bu on yıl, çekirdek torbalama, artırma ve istifleme yöntemleri gibi en popüler ve yaygın olarak kullanılan yöntemlerle ilgili makalelerin yayınlandığı zaman olmuştur (Brownlee, 2020).

Topluluk yöntemleri, hesaplama maliyetini ve karmaşıklığını büyük ölçüde artırır. Bu artış, tek bir modelden ziyade birden çok modeli eğitmek ve sürdürmek için gereken uzmanlık ve zamandan kaynaklanıyor. Tek bir model üzerinde bir topluluk öğrenimi kullanmanın iki ana nedeni vardır ve bunlar birbiriyle ilişkilidir; onlar:

- Performans: Bir topluluk, katkıda bulunan herhangi bir modelden daha iyi tahminlerde bulunabilir ve daha iyi performans elde edebilir.
- Sağlamlık: Bir topluluk, tahminlerin ve model performansının yayılmasını veya dağılmasını azaltır.

Topluluk öğrenimi, tahmine dayalı bir modelleme probleminde tek bir tahmine dayalı modelden daha iyi tahmin verim elde etmek için kullanılır. Bunun başarıma yolu, önyargı ekleyerek tahmin hatasının varyans bileşenini azaltan model olarak anlaşılabilir (yani yanlılık-varyans değiş tokuşu bağlamında). Topluluk yöntemlerinin bir başka önemli ve daha az tartışılan yararı, bir modelin ortalama performansında geliştirilmiş sağlamlık veya güvenilirliktir. Bunların her ikisi de bir makine öğrenimi projesiyle ilgili önemli endişelerdir ve bazen bir modelin özellikleri veya ikisi birden tercih edilebilir.

Tüm bu anlatılanlar çerçevesinde makine öğrenimi için topluluk yöntemlerinin faydalarından bahsedilmesi gerekmektedir. Topluluk öğrenimi, iki veya daha fazla başka modelden gelen tahminleri birleştiren tahmine dayalı modellerdir. Toplu öğrenme yöntemleri ve bir tahmine dayalı modelleme projesinde en iyi performansın en önemli sonuç olduğu durumlarda kullanılabilir (Brownlee, 2020).

### **2.5.6. Karar ağaçları (decision trees)**

Karar Ağaçları, verilerin belirli bir parametreye göre sürekli olarak bölündüğü bir Denetimli Makine Öğrenimidir, yani, girdinin ne olduğunu ve eğitim verilerinde



karşılık gelen çıktının ne olduğunun açıklandığı durumdur. Ağaç, iki varlık, yani karar düğümleri ve yapraklar ile açıklanabilir. Yapraklar kararlar veya nihai sonuçlardır. Karar düğümleri, verilerin bölüdüğü yerdir (Xoriant, 2017).

### **2.5.7. Lineer ayırtaç analizi (linear discriminant analysis)**

Lineer Ayırtaç Analizi (LDA), en yaygın olarak, model sınıflandırması ve makine öğrenimi uygulamaları için ön işleme adımında boyut azaltma tekniği olarak kullanılmaktadır. Amaç, aşırı uyumdan kaçınmak ve ayrıca hesaplama maliyetlerini düşürmek için iyi bir sınıf ayrılabilirliğine sahip daha düşük boyutlu bir alana bir veri kümesini yansıtmaktır (Raschka, 2014).

## **2.6. Derin Öğrenme**

Derin Öğrenme, Yapay Zekanın bir alt kümesi olan Makine Öğreniminin bir alt kümesidir. Yapay Zeka, bilgisayarların, insan davranışını taklit etmesini sağlayan tekniklere atıfta bulunan genel bir terimdir. Makine Öğrenimi, tüm bunları mümkün kılan veriler üzerinde eğitilmiş bir dizi algoritmayı temsil eder. Öte yandan Derin Öğrenme, insan beyninin yapısından esinlenen bir tür Makine Öğrenmesidir. Derin öğrenme algoritmaları, verileri belirli bir mantıksal yapı ile sürekli olarak analiz ederek insanların yapacağı gibi benzer sonuçlar çıkarmaya çalışır. Bunu başarmak için, derin öğrenme, sinir ağları adı verilen çok katmanlı bir algoritma yapısı kullanır (Oppermann, 2019).

Derin öğrenmenin yapısı YSA diyagramına dayanmaktadır. YSA ile karşılaştırıldığında daha iyi sonuçları elde edilebilecek olan bir yöntemdir. Şimdiye kadar, çoğu makine öğrenimi ve sinyal işleme aşamaları derin yapılmayan yapılardan oluşmaktaydı. Bunlar yapı itibarıyla en fazla bir veya iki kat nonlinear özellik dönüşümleri dahildir. Bu tarz mimarilere örnek olarak Gaussian Mixture Models (GMMs), lineer veya nonlinear fiziksel sistemler, Conditional Random Fields (CRFs), Multi Layer Perceptrons (MLP), maksimum entropi (MaxEnt) modelleri, Logistic Regression, Kernel Regression, SVM'ler ve bir gizli katman içeren Extreme Learning Machines. Derin olmayan mimariler, basit veya iyi sınırlanmış problemleri çözmede başarılı olsada sınırlı modelleme ve temsil gücü gibi oldukça

karmaşık gerçek uygulamalarla uğraşırken bir takım zorluklara sebep olmuştur (Deng, Li, Liu, 2018). Bu mimari modelleme yapmak ve çözümlene için derin mimarilerin çok daha basit şekilde yapılacağını göstermiştir.

Derin Sinir Ağları (DSA) olarak isimlendirilen pekçok gizli katmana sahip olan ileri besleme ağları (Feed-Forward Neural Networks) veya MLP'ler, derin bir yapıdaki modellerin ilk örneğidir.

Derin öğrenme algoritması oluşturulurken Python başvuru diline geldi ve TensorFlow ve PyTorch gibi popüler güçlü derin öğrenme kütüphaneleri kullanılmaktadır. Bu seride, Keşifsel Veri Analizi, Veri Ön İşleme gerçekleştirmek ve son olarak bir Derin Öğrenme Modeli oluşturmak ve değerlendirmek için Keras'ı kullanacağız. Bu aşamada, eğiteceğimiz ve daha sonra el hareketini tahmin etmek için kullanacağımız derin bir sinir ağı modeli oluşturacağız.

### **2.6.1. Modelin Tanımlanması**

Derin öğrenme sinir ağı, yalnızca birçok gizli katmana sahip bir sinir ağıdır. Modelin tanımlanması birkaç özelliğe ayrılabilir:

- Katman sayısı
- Bu Katmanların Türleri
- Her Katmandaki birim (nöron) sayısı
- Her Katmanın Aktivasyon Fonksiyonları
- Giriş ve çıkış boyutu

### **2.6.2. Derin Öğrenme Katmanları**

Derin öğrenme modelleri için birçok katman türü vardır. Görüntüleri sınıflandıran veya nesne tespiti yapan CNN'lerde evrişim ve havuzlama katmanları kullanılırken, doğal dil işleme ve konuşma tanımada yaygın olan RNN'lerde tekrarlayan katmanlar kullanılır. Dense ve Dropout katmanlarını kullanacağız. Dense katmanlar en yaygın ve popüler katman türüdür - bu yalnızca nöronlarının her birinin önceki ve sonraki katmanın nöronlarına bağlı olduğu normal bir sinir ağı katmanıdır. Her Dense katman,

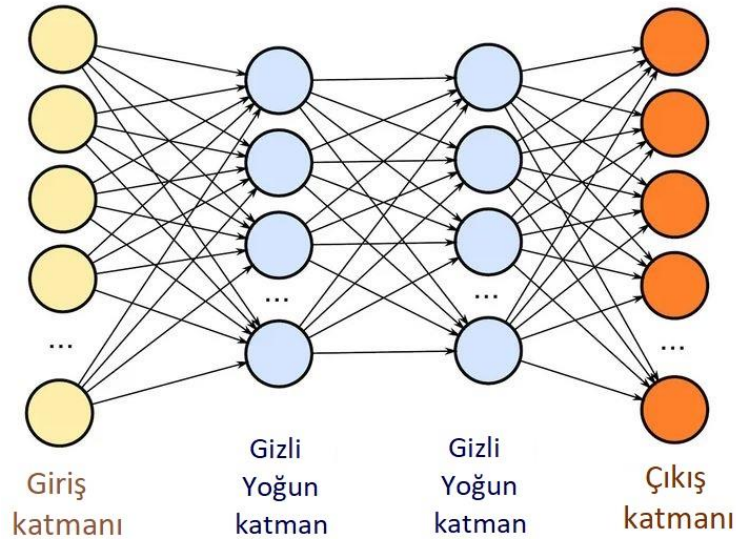
sinapların girdilerine ve ağırlıklarına dayalı olarak nöronlarının çıktısını belirleyen bir aktivasyon fonksiyonuna sahiptir. Dropout katmanları, giriş birimlerinin bazılarını rastgele 0'a düşüren yalnızca düzenleme katmanlarıdır. Bu, sinir ağına aşırı uyuma olasılığını azaltmaya yardımcı olur.

### 2.6.3. Aktivasyon Fonksiyonları

Ayrıca katmanlara uygulanabilecek birçok türde aktivasyon fonksiyonu vardır. Her biri nöronun girdisini ve ağırlıklarını farklı bir şekilde birbirine bağlar ve ağına farklı davranmasını sağlar. ReLU (Doğrultulmuş Doğrusal Birim), Sigmoid fonksiyonu ve Doğrusal fonksiyon gerçekten yaygın fonksiyonlardır. ReLU, derin öğrenme modellerinde çoğunlukla kullanılan aktivasyon fonksiyonudur. İşlevi, herhangi bir negatif girdi alırsa 0 değerini döndürür, ancak herhangi bir pozitif değeri için o değeri geri döndürür (Kaggle, 2021).

### 2.6.4. Giriş ve Çıkış katmanları

Gizli katmanlara ek olarak, modellerde bir giriş katmanı ve bir çıktı katmanı bulunur. Şekil 2.15'de Derin öğrenme ağ yapısı (deeplearning, 2020) gösterilmektedir.



Şekil 2.15 : Derin öğrenme ağ yapısı

Girdi katmanındaki nöron sayısı, verilerimizdeki öznitelik sayısından farklıdır. Ağa bu özelliklere tepki vermeyi öğretmek istiyoruz. Çıktı katmanı, nöron sayısı hedefinize bağlıdır. Bu tez çalışmasında giriş katmanı bizim özelliklerimizi temsil ederken gizli katman eğitim verilerinin ve çıkış katmanı ise tanımlanan hareket sınıfı ile ne düzeyde doğru tahmin yapıldığıyla ilgili sonuçları vermektedir.

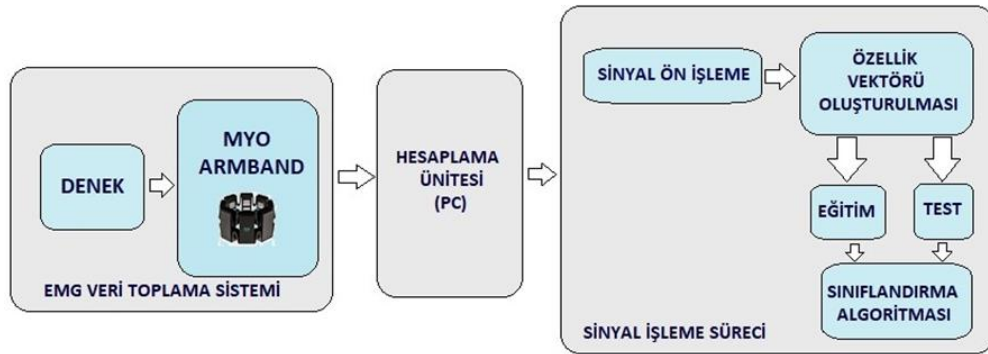


## BÖLÜM 3. MATERYAL VE METHOD

Bu bölümde EMG sinyallerinin ön işleme adımları, işlenen sinyalden öznelik çıkarma yöntemleri ve elde edilen özelliklere göre EMG sinyallerinin sınıflandırılması konuları aktarılmıştır.

### 3.1. Deneysel Çalışma

Deneysel çalışmalar bölümünde ilk olarak kullanılan açık kaynak EMG veri setinin katılımcı verileri bilgisayar ortamına aktarılmıştır. Bu EMG verileri yazılım programı (Matlab, Python) ortamına aktarılıp çeşitli ön işleme adımlarından geçirildikten sonra, her bir hareket için özellik vektörleri oluşturularak, hareket için tanımlı sınıfa ayrılıp makina öğrenmesi için denetimli öğrenme ağları kullanılarak eğitilip test aşamasına geçilmiştir. Farklı özellik kümelerine ait sınıflandırılan eğitim sonuçları, test sonuçları ve kullanılan EMG verileri için doğruluk değerlendirmesi yapılan öğrenme ağları, sınıflandırma performans tabloları ve grafikleriyle gösterilmiştir. Sınıflandırma algoritması, K-en yakın komşular (k-NN), Destek vektör makineleri (SVM), Doğrusal Regresyon (Lineer regresyon), Karar ağaçları (Decision Tress), Toplu öğrenme (Ensemble learning), Ayırtaç analizi (Discriminant Analysis) kullanılmıştır. Bu çalışmanın işleyiş süreci Şekil 2.1’de görülmektedir.




Şekil 3.1 : Emg verilerinin sınıflandırılması için önerilen çalışmanın şeması

### 3.2. EMG Verilerinin Toplanması ve Katılımcı Bilgileri

Bu tez çalışmasında, alınan EMG verilerinin kayıtları, kullandığım açık kaynak EMG veri setinin Thalmic Labs tarafından geliştirilen Myo Armband kullanılarak alınması ile oluşturulmuştur (B. De la Cruz-S´anchez, M. Arias-Montiel, and E. Lugo-Gonz´alez, 2019).

Bu çalışmada kullandığım veri setinin hareketleri: yumruk (Fist), küre kavrama (Cilindro Spherical Grasp), silindirik kavrama (Clindrical Grasp) ve kalem sıkıştırma (Tip Pinch) gibi benzer hareketlerden oluşmaktadır. Bu hareketler sağlıklı kişiler tarafından alınmış olup ve insanların günlük yaşamlarında aktivitelerin gelişimi sırasında gerekli olan hareketlerden oluşturulması sağlanmıştır. Silindirik kavrama egzersizleri için katılımcıya, 8 cm çapında ve yaklaşık 12 cm uzunluğunda plastik bir silindir ile egzersiz yaptırılmış. Küresel kavrama egzersizleri için 9 cm çapında plastik, küre kavrama için kullanılmış. Hassas kavramanın geliştirilmesi için katılımcıya, başparmağı ve işaret parmağıyla ticari bir kalem alınması sağlanmıştır. Yumruk için ise katılımcının sadece yumruğunu kapatması ve test bitene kadar bu pozisyonda tutması söylenmiştir. Şekil 2.2’de veritabanının oluşturulduğu dört temel hareket gösterilmektedir (B. De la Cruz-S´anchez, M. Arias-Montiel, and E. Lugo-Gonz´alez, 2019).



Şekil 3.2 : Kullanıcı tarafından yapılacak el hareketleri.a) Silindir kavrama b) Küre kavrama c) Yumruk d) Hassas kavrama

Katılımcılardan alınan bu verilerin sınıflandırma algoritmasında eğitmek için büyük bir veritabanı oluşturmak gerekir. Bu nedenle, yukarıda açıklanan her hareket için verilerin 5 saniye süreyle kaydedildiği belirtilmiştir. Genellikle katılımcı, hareketini 3 saniyede gerçekleştirip; kalan sürede katılımcının tepki vermesi ve hareketi gerçekleştirme için bir marj görevi (oluşabilecek hatalara karşı verilen zaman) görmesi sağlanmıştır. Her hareket için farklı katılımcılarla 225 test yapılmış olup dört hareket için ise toplam 675 test yapılmıştır. Tüm testler dominant olmayan ele karşılık gelen kol ile yapılıp, deneklerin yaşı, her iki cinsiyetten 20 ila 45 yaş arasında oluşturulması sağlanmıştır. Kullandığımız bu veri seti Japonya Ulusal İleri Bilim Teknoloji Enstitüsü tarafından el hareketlerinin tanınması S-CRC (Spectral Collaborative Representation)'ye dayalı temsil tabanı sınıflandırmalarda kullanılmak üzere hazırlanmıştır. EMG sinyalleri gönüllülerden elde edilip, veri tabanı açık erişimlidir (B. De la Cruz-S'anchez, M. Arias-Montiel, ve E. Lugo-Gonz'alez, 2019). Katılımcılardan alınan verilerin hareketlere göre test sayıları Tablo 3.1'de gösterilmiştir.

Tablo 3.1 : Cinsiyet ve el hareketine göre toplanan örnek sayısı.

Hareket	Cinsiyet	Katılımcı (Test) Sayısı
Yumruk	Erkek	146
	Kadın	79
Silindir Kavrama	Erkek	146
	Kadın	79
Kalem sıkıştırma	Erkek	146
	Kadın	79
Küre Kavrama	Erkek	146
	Kadın	79

Numunelerin her biri, Myo TM Armbandının sekiz sEMG sinyalinin her biri için 1000 veri noktasına sahip ayrı bir .txt uzantı dosyasında saklanmıştır.

**MyoArm Band:** Teknolojini ilerlemesiyle giyilebilir teknolojiler hayatımızda pek çok yerde karşımıza çıkmaktadır. İnsan bedenindeki kas hareketlerini algılayabilen bu tip cihazlar geliştirilmekte ve ticari olarak sunulmaktadır. Bu teknolojilerin gelişmesi ve özellikle engelliler için çeşitli uygulamalarda kullanılması engelliler için cihaz

kontrolündeki yeniliklerin önünü açmaktadır (Küçüküydüz, G., Ocak, H., Şayli, Ö., ve Karakaya, S., 2015). Şekil 2.3’de Thalmic Labs tarafından geliştirilen Myo Armband modeli gösterilmiştir (Thalmic Lab., 2020).



Şekil 3.3 : Thalmic Myo Armband

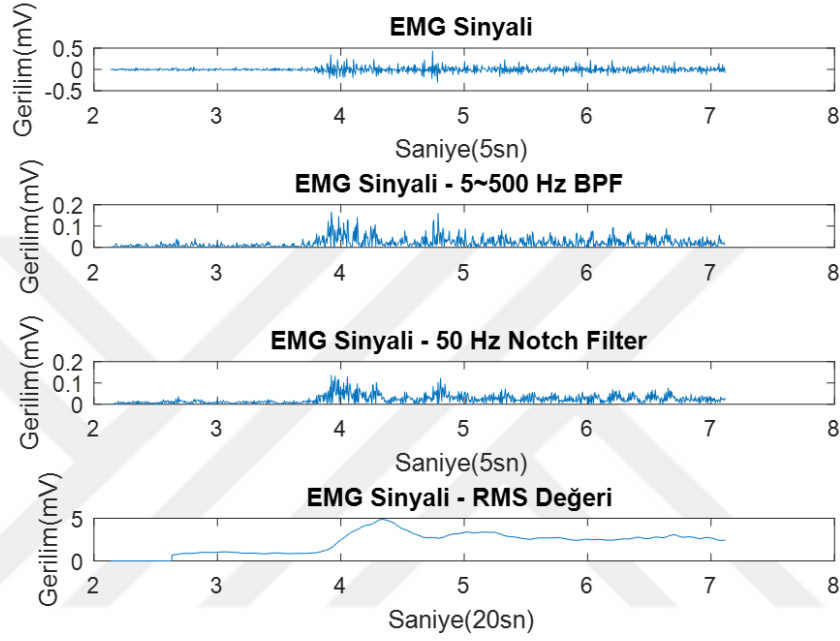
Şekil 2.3’de görüldüğü üzere EMG Myo armband kol kaslarından EMG sinyallerini alabilen dairesel şekilde konulandırılmış olan sekiz adet EMG sensörü bulundurmaktadır. EMG sensörleri ile kol bandında ivmeölçer, jiroskop ve manyetometre bulunmaktadır. Myo Arbandı bilgisayar ve bluetooth ile haberleşmektedir. Myo’nun yazılım geliştirme kiti (SDK), geliştiricilerin Myo’dan bluetooth bağlantılı bir bilgisayara aktarılan ham verilere erişmesine olanak tanır. . Thalmic Labs tarafından verilen yazılım geliştirme kiti kullanılarak bu ham veriler, yerleşik ivmeölçer, jiroskop, yönelim ve EMG sensörlerinin çıktılarına ulaşmak mümkündür (Abreu, J. G., Teixeira, J. M., Figueiredo, L. S., ve Teichrieb, 2016; Küçüküydüz, G., Ocak, H., Şayli, Ö., ve Karakaya, S., 2015). Bu tez çalışmasında EMG (elektromiyografi) verilerini kullandığımız kayıtlar, Thalmic Labs tarafından geliştirilen Myo Armband kullanılarak yapılmıştır.

### **3.3. Elde Edilen EMG Sinyallerinin İşlenmesi**

Kullanılan hazır veri seti Matlab programında sinyal işleme adımlarından ham EMG sinyalinin alınması ile sinyale tam dalga doğrultma işlemi yapılmış olup, herbir hareket için sinyallere 5 Hz' lik bir kesme frekansında (butterworth) üçüncü dereceden bant geçiren filtre ile düzeltilip ve filtrelenmiştir. Bu çalışmada kaydedilen EMG sinyalleri 1 kHz'lik örnekleme frekansı değeriyle örneklenmiştir. Bir EMG sinyali için standartlara göre, yüzey EMG sinyallerinin güç yoğunluğu fonksiyonu, 5-10 Hz aralığı dışında ihmal edilebilir katkılara sahiptir. EMG sinyalinin düzeltilmesi, beyaz Gauss

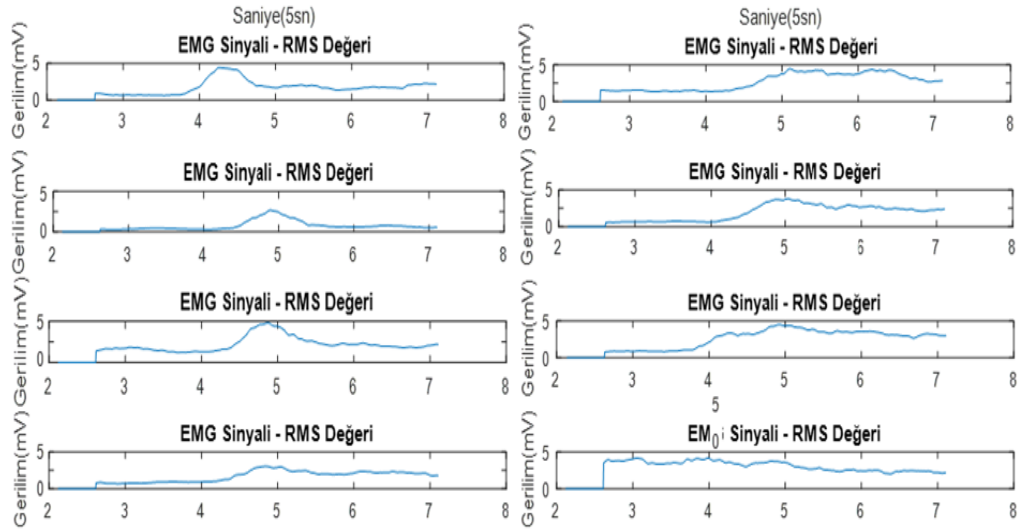


gürültüsünü ortadan kaldırmak ve yalnızca kas aktivitesi bilgisini içeren çok düşük frekans modülasyonlu sinyallerle çalışmak için kanalların her biri için mutlak değer fonksiyonu uygulanmıştır. 50 Hz şehir şebekesi gürültüsünü yok etmek için ise band durduran (Notch) filtre kullanılmıştır. İşlenen sinyal çıktıları aşağıda Şekil 2.4'de gösterilmektedir.



Şekil 3.4 : İşlenmiş EMG sinyali çıktıları

Sinyal işleme adımlarından sonra her bir hareket için özellik vektöründen oluşan Matlab'ta kod programı hazırlanmış kullanılan özellik vektörleri Dalga Biçimi Uzunluğu (WL), Ortalama Mutlak Değer (MAV), Ortalama Kök Kareler (RMS), Basıklık (Kutozis) ,Sıfır Geçiş (ZC), Willison Amplitude (WAMP), Eğim İşareti Değişiklikleri (SSC), Entropi (H), Otoregresif model (AR), Varyans (VAR) olmak üzere on özellik ile ayrı ayrı her bir hareket için normalize hale getirilip sınıflandırma algoritması için hazırlanmıştır. Aşağıdaki şekilde 8 kanallı yumruk (Fist) hareketi için işlenmiş EMG sinyali görülür. Şekil 2.5'de Yumruk hareketi için EMG sinyal işlemenin sekiz sensör çıktı grafiği gösterilmiştir.



Şekil 3.5 : Yumruk hareketi için EMG sinyal işlemenin sekiz sensör çıktı grafiği

### 3.4. EMG Sinyallerinin Sınıflandırılması

Bu çalışmada hazırlanan sınıflandırma algoritması Matlab Classification Learner uygulamasını kullanarak Makine öğrenmesi methodlarından En yakın K-komşu algoritması (k-NN), Destek vektör makineleri(SVM), Toplu Öğrenme (Ensemble learning), Karar ağaçları (Decision Tress) sırasıyla eğitilip test aşamasından geçirilmiştir.

#### 3.4.1. Karar ağaçları (Decision Tree)

Kullanılan Karar ağaçları (Decision Tree) için sistemde denenen çeşitli girdilere ait özellikler verilmiştir. Bu tablodan model metriklerini girerek Maksimum Parti Bölme Sayısı, ağacın derinliğini kontrol etmek için, max bölme ve dal noktası sayısını belirler, Bölme kriterleri; bölme ölçütü sapma azaltmadır ve sınıflandırma ağacında, yalnızca bir sınıf içeren saf düğümleri optimize etmeye çalışır. Gini'nin çeşitlilik indeksi (varsayılan) ve sapma kriteri düğüm kirliliğini ölçer. Maksimum Parti Bölme Sayısı, yalnızca eksik veriler için karar bölmeleri için vekil kullanımı belirtir. Eksik değerlere sahip veriler varsa, tahminlerin doğruluğunu artırmak adına aşağıdaki tablodaki özellikler değiştirilerek olabilecek en iyi tahmin değerlerine ulaşılmaya çalışılmıştır. Aşağıdaki Tablo 3.2' de Karar ağaçları'na ait özellik değerleri verilmiştir.

Tablo 3.2 : Karar ağaçları özellikleri tablosu

Model	Maksimum Parti Bölme Sayısı	Bölme kriterleri	Vekil karar bölmesi
Fine Tree	1-100	Gini'nin çeşitlilik indeksi	Off
Medium Tree	1-100	Gini'nin çeşitlilik indeksi	-
Course Tree	1-100	Gini'nin çeşitlilik indeksi	-

Karar ağaçları modeli yorumlanması kolay, tahminleri hızlı , bellek kullanımı düşüktür ve elde edilen sonuçlara göre Fine tree max 100 bölme sayısına medium tree max 20 bölme sayısına course tree max 4 bölme sayısına sahip olduğundan Karar ağacı modelinde yukarıda denenen özelliklere göre sırasıyla %77.6, %75.2, %63.4 değerinde kendi içinde olabilecek en iyi doğruluk tahminlerine ulaşılmıştır.

### 3.4.2. Destek vektör makineleri (SVM)

Destek vektör makineleri analizi tablosunda sınıflandırıcıyı hesaplamak, çarpanların izin verilen değerlerini sınırlı bir bölgede tutmak, bir sınıfı diğerlerinden ayırt etmek ve mesafe ölçümlerini ayarlamak için tablodaki değerler alınan doğruluk değerine göre değiştirilmiştir. Kernel Fonksiyon, sınıflandırıcıyı hesaplamak için çekirdek işlevini belirtir. Kernel oran model, çekirdek ölçek modunu Auto olarak ayarladığında, yazılım ölçek değerini seçmek için buluşsal bir prosedür kullanır. Kutu kısıtlama düzey ise Lagrange çarpanlarının izin verilen değerlerini bir kutuda, sınırlı bir bölgede tutmak için kutu kısıtlamasını belirtir.

Destek vektör makineleri modeli yorumlanması Lineer SVM için kolay diğer türler için zordur, tahmin etme oranları orta hızdadır ve elde edilen sonuçlara göre SVM modelinde yukarıda denenen özelliklere göre sırasıyla %84.9, %87.2, %84.9, %77.8, %82.2, %84.94 değerinde kendi içinde olabilecek en iyi doğruluk tahminlerine ulaşılmıştır. Tablo 3.3'de SVM özellikler değerleri verilmiştir.

Tablo 3.3 : Destek vektör makineleri özellikleri

Model	Kernel fonksiyon	Kernel oran model	Kutu kısıtlama düzeyi
Linear SVM	Gaussian	Auto	1
Quadric SVM	Gaussian	Auto	40
Cubic SVM	Cubic	Auto	1
Fine Gauss SVM	Gaussian	2.5	40
Coarse G. SVM	Gaussian	Auto	40
Medium SVM	Gaussian	10	41

### 3.4.3. Toplu öğrenme (Ensemble learning)

Topluluk sınıflandırıcıları, birçok zayıf veriden elde edilen sonuçları tek bir yüksek kaliteli topluluk modelinde birleştirir. Nitelikler, algoritma seçimine bağlıdır. Modelin Öğrenme tipi, optimize edilemeyen topluluk sınıflandırıcı seçeneklerinin her birinde mevcuttur. Verilerle en iyi modeli hangi ayarların ürettiğini görmek için hepsini eğitilmesi gerekir. Büzülme için öğrenme oranı belirtilir. Öğrenme oranını 1'in altına ayarlanması durumunda, topluluk daha fazla öğrenme yinelemesi gerektirir ancak genellikle daha iyi doğruluk elde eder. 0.1 popüler bir seçimdir. Şekil 3.4'de toplu öğrenme özellikleri verilmiştir.

Tablo 3.4 : Toplu öğrenme özellikleri

Model	Toplu öğrenme metodu	Öğrenme Tipi	Öğrenme Oranı
Boosted Tree	Ada Boost	Karar Ağacı	0.1
Bagged Trees	Bag	Karar Ağacı	30
S. Discriminant	Subspace	Discriminant	52

Toplu öğrenme algoritmasına öğrenme tiplerine göre, öğrenme oranı değerleri kıyaslanmıştır bu değerlere göre S. Discriminant modelinde en yüksek öğrenme oranına sahip olmasına rağmen Bagged Tree doğruluk tahmini değeri daha yüksek

çıkılmıştır .Buradan anlaşılacağı üzere Karrar ağacı modeli Discriminant modeline göre daha yüksek verimlilik alınan algoritma tipidir.

#### 3.4.4. K-komşu Algoritması (k-NN)

Tablo 3.5’ de k-NN modelinde tahmin yaparken her noktayı sınıflandırmak için bulunacak en yakın komşu sayısı değeri, noktalara olan mesafeyi belirlemek için mesafe metriği, mesafe fonksiyonu ve doğrulama (Cros Validation) seçerek modelin görmediği veriler üzerinde ki performansını mümkün olduğunca doğru şekilde değerlendirmek için kullanılan örnekleme yöntemleri özellikleridir. Aşağıda ki Tablo 3.5’de k-NN’e ait özellikler verilmiştir.

Tablo 3.5 : k-NN sınıflandırma parametreleri

Paremetreler	Değer
Komşu sayısı	1
Mesafe fonkdiyoyu	Spearman
Mesafe	Eşit
Doğrulama	50

Tablo 3.5’ de k-NN modelinde tahmin yaparken her noktayı sınıflandırmak için bulunacak en yakın komşu sayısı değeri 1, 10 ve 100 olan farklı modeller eğitilip alınan değerler sırasıyla olarak değiştirilip %87.6, %80.4, %79.7, %78.4, %73.0, %81.2 değerinde kendi içinde olabilecek en iyi doğruluk tahmini alınmıştır.

Değerlendirme kriteri olarak karşıklık matrisi ve roc eğrisi ayrıca kullanılmıştır. Kısaca bahsedecek olursak:

**Karışıklık Matrisi:** Gerçek değerlerin bilinmekte olduğu bir dizi veri seti üzerinde bir sınıflandırma modelinin performansını değerlendirmek için sıklıkla kullanılan bir tablodur. Buradaki ifadeler:

**Gerçek Pozitifler (TP):** Bunlar gerçek değeri 1 ve tahmin ettiğimiz değer de 1 olduğu örneklerdir.

**Gerçek Negatifler (TN):** Bunlar gerçek değeri 0 ve tahmin ettiğimiz değer de 0 olduğu örneklerdir.

**Yanlış Pozitifler (FP):** Bunlar gerçek değeri 0 ancak tahmin ettiğimiz değerin 1 olduğu örneklerdir.

**Yanlış Negatifler (FN):** Bunlar gerçek değeri 1 ancak tahmin ettiğimiz değerin 0 olduğu örneklerdir.

**Doğruluk (Accuracy):** Doğru sınıflandırmanın toplama bölümüdür.

$$\text{Doğruluk} = \text{TN} + \text{TP} / \text{TOPLAM} \quad (3.1)$$

**Yanlış Sınıflandırma Oranı (Misclassification Rate):** Genel olarak, sınıflayıcının ne sıklıkta yanlış tahmin ettiğinin belirtir. Hata Oranı olarak da bilinir (Error Rate).

$$\text{Hata Oranı} = (\text{FP} + \text{FN}) / \text{TOPLAM} \quad (3.2)$$

**Doğru Pozitif Oranı/Duyarlılık/Hassasiyet (True Positive Rate – Sensivity):** Doğru olarak tahmin edilen varların (TP) gerçek varlara oranı. Modelin doğruları bilme konusundaki etkinliği de denilebilir.

$$\text{Duyarlılık} = \text{TP} / \text{Gerçek Varlar} \quad (3.3)$$

**Yanlış Pozitif Oranı (False Positive Rate):** Gerçek değeri 0 olmasına karşın 1 olarak tahmin edilenlerin oranıdır. Yan Ürün olarak da bilinir.

$$\text{FP} / \text{GERÇEK NEGATİFLER} \quad (3.4)$$

**Yanlış Negatif Değerlerin Oranı (False Negative Rate):** Gerçek değeri 1 olmasına karşın 0 olarak tahmin edilenlerin oranıdır. Kayıp oranı olarak da bilinir. (Miss Rate)

$$\text{FN} / \text{GERÇEK POZİTİFLER} \quad (3.5)$$

**Gerçek Pozitif Değerlerin Oranı (True Positive Rate):** Sınıflayıcının ne kadar gerçek pozitif değeri doğru tahmin ettiğinin bir ölçüsüdür. Hassasiyet, İsabet Oranı veya Hatırlama olarak da bilinir. (Sensitivity, Hit Rate or Recall)

$$\text{TP} / \text{GERÇEK POZİTİFLER} \quad (3.6)$$

**Gerçek Negatif Değerlerin Oranı (True Negative Rate):** Sınıflayıcının ne kadar gerçek negatif değeri doğru tahmin ettiğinin bir ölçüsüdür. Özgüllük veya Seçicilik olarak da bilinir (Specificity or Selectivity).

$$\text{TN} / \text{GERÇEK NEGATİFLER} \quad (3.7)$$

### 3.4.5. Derin öğrenme

Bu tez çalışmaları sonucunda sınıflandırma algoritmasında doğruluk tahmini açısından daha verimli sonuçlar almak amacıyla farklı bir alan olarak derin öğrenme algoritmasında denemeler yapılmıştır. En az hatayı veren modeli ve en çok doğru olan global minimum noktasını bulmak adına python programlama ile derin öğrenme algoritması uygulanmıştır. Bu method doğrultusunda bu modeli somutlaştırmak için Sequential modeli tercih edilmiştir. Bu çalışmada kullanılan veri tabanı 900 satır 80 sütundan oluştuğu için 4 katmanlı model kullanılmıştır. Katman sayısını artırmak aşırı öğrenmeye (overfitting) neden olacağı için bu kısımda dropout kullanılmıştır. Dropout kullanılmasının nedeni giriş katmanı ile gizli katman arasındaki geçişte her defasında %50 veya %20'lik kısmı kapatıp sistemin eğitmesinin aşırı öğrenmesini engellemektir. Burada aksiyon fonksiyonu olarak RELU kullanılmıştır. RELU aksiyon fonksiyonu kullanarak modelin doğrusal olmayan bir özelliği çıkarması sağlanmıştır. Tablo 3.6'da eğitim ve test aşamasında kullanılan modeller ve değerleri gösterilmektedir.

Tablo 3.6 : Derin öğrenme model eğitim özellikleri

Model	Katman	Zamanın başlangıcı (epoch)	Girdi sayısı (batch size)
Sıralı (Sequential)	32..128	50	128
Sıralı (Sequential)	64..256	250	256

Tablo 3.6'da sıralı katman (sequential dense) kısmı, gizli katman için kullanılan katman yoğunluk değerleridir. Model eğitilme işlemi yapılırken verilerin bütünü aynı zaman diliminde eğitime katılmaz, belirlenen sayıda parça bütünleri halinde eğitimde yer alırlar ve bu işlem her bir eğitim adımında aynı şekilde tekrarlanarak model için en uygun olan ağırlık değerleri hesaplanmaya çalışılır ve girdi sayısı, her bir adımda kaç örneklemin model parametrelerinde değişiklik yapılacağını belirtmek için kullanılır. Zamanın başlangıcı (epoch) değeride bütün örneklerin model içinden kaç kez geçeceğini ifade eder. Alınan sonuçlar doğrultusunda farklı bir alan olarak denenen CNN derin öğrenme algoritmasından verimli sonuçlar alınmamış olup burada bir takım değişikliklere gidilip başka eğitim modelleri ile karşılaştırılma yapılabilir. Kullanılan bu yöntem makine öğrenmesi ile karşılaştırma olmayıp, sadece alternatif bir çözüm adına veri seti üzerinde denenmiştir.

## BÖLÜM 4. SONUÇLAR VE TARTIŞMA

Yapılan çalışmalar sonucunda Makine öğrenmesi uygulamalarından alınan en yüksek performans sınıflandırma algoritması ortalama olarak % 87.6 değerinde k-NN Yakın Komşuları ve %87.2 değerinde Destek Vektör makineleri algoritmalarıdır. Sınıflandırıcı girdi verileri sonuçları Tablo 4.1'te gösterilmektedir.

Tablo 4.1 : Kullanılan sınıflandırma methodlarının tahmin doğruluk değerleri

Model	Doğruluk	Tahmin hızı	Eğitim zamanı	AUC
Fine Tree	%77.6	1800 obs/sec	5.058 sec	0.80
Medium Tree	%75.2	2200 obs/sec	6.355 sec	0.84
Course Tree	%63.4	2100 obs/sec	12.901 sec	0.72
Linear SVM	%84.9	970 obs/sec	15.695 sec	0.96
Quadric SVM	%87.2	1100 obs/sec	16.212 sec	0.95
Cubic SVM	%84.9	1000 obs/sec	25.267 sec	0.95
Fine Gauss SVM	%77.8	720 obs/sec	28.118 sec	0.91
Coarse G. SVM	%82.2	990 obs/sec	17.341 sec	0.95
Medium G. SVM	%84.9	920 obs/sec	23.889 sec	0.94
Boosted Tree	%83.7	550 obs/sec	128.25sec	0.96
Bagged Trees	%86.9	530 obs/sec	32.147 sec	0.96
S.Discriminant	%81.2	320 obs/sec	26,834 sec	0.93
Fine k-NN	%87.6	390 obs/sec	6.899 sec	0.92
Medium k-NN	%80.4	1500 obs/sec	4.0389 sec	0.93
Cubic k-NN	%79.7	270 obs/sec	11.436 sec	0.91
Cosine k-NN	%78.4	900 obs/sec	4.034 sec	0.91
Coarse k-NN	%73.0	1300 obs/sec	3.374 sec	0.88
Weight k-NN	%81.2	1100 obs/sec	3.333 sec	0.94



Tablo 4.1’de denetimli öğrenme modellerinin tahmin hızları, eğitim zamanı ve modelin eğitmede ki başarı değerleri gösterilmektedir. Tablodan görüldüğü üzere en iyi tahmin değerinin Fine k-NN ve Quadric SVM algoritmalarında verdiği görülmektedir. Alınan bu değerlerle elde edilen veriler sonucunda performans değerlendirme metriklerini görmek için Karışıklık Matrisi (Confusion Matrix)’nden veri setinde var olan k-NN modelimizin doğru ve yanlış tahminlerinin sayısal verileri incelenmiştir. k-NN algoritmasında değerlendirme yaparken, özelliklerin sayısının artırılmasına gidilse de doğruluk performansının belli düzeyde değiştiğini, çok sayıda özelliğin daha yüksek bir performansı garanti etmediği görülmüştür. Özellik sayısı olarak 10 farklı özelliğin benzer hareketlerin sınıflandırılmasında ideal olabileceği veri sonuçlarından öngörülmüştür. Bu sınıflandırma modelinin performansını değerlendirmek için Şekil 4.1’de k-NN algoritması karışıklık matrisi aşağıda görülmektedir.

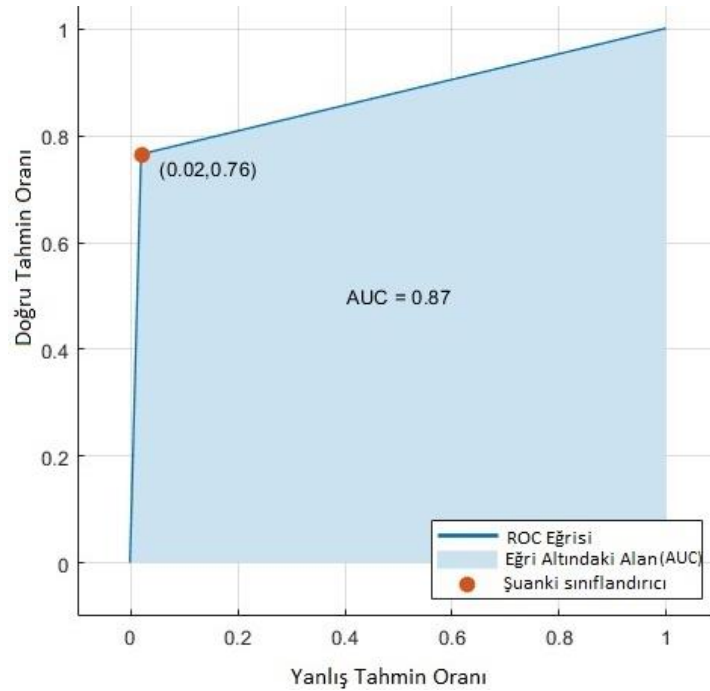
**Model 6**

Doğru Sınıf	0	92%	2%	10%	10%
	1	2%	91%	3%	5%
	2	6%	3%	87%	4%
	3		4%	<1%	81%
Doğru Tahmin Değeri		92%	91%	87%	81%
Yanlış Bulgu Oranı		8%	9%	13%	19%
		0	1	2	3
		Tahmin Sınıfı			

Şekil 4.1 : k-NN algoritması karışıklık matrisi tablosu


Karışıklık matrisi tablosundaki 0, 1, 2, 3 hareket sınıflarımızı nitelendirmekte olup, gerçek pozitif (true positive) tahmin değerleri modelin doğru tahmin ettiği yüzdelik dilimi ifade etmektedir. Yanlış pozitif değerleri (false positive) ise modelin her hareketten ne derece yanlış tahminde bulunduğunu göstermektedir. Şekil 3.1’de 0.hareket (yumruk hareketi) için %92 doğru tahminde bulunmakta iken %2’sini 1. hareket olarak %10’unu 2. hareket ve diğer %10’unu ise 3.hareket olarak yanlış tahminde bulunmaktadır. Makine öğrenmesinde performans ölçüm grafiklerinden ROC eğrisi sınıflandırma performans eğrilerinden biridir. Buradada sınıflandırmanın ne kadar iyi düzeyde yapıldığını görmek adına ROC eğrisi değerlendirme olarak kullanılmıştır.

**ROC Eğrisi (ROC Curve):** Bu, sınıflandırıcının tüm olası değerler üzerinde performansını özetlemek için kullanılan bir grafikdir. Belirli bir sınıfa gözlem atanması eşliğini değiştirdiğinizde Gerçek Pozitif Değerlerin Oranına (Hassasiyet) (x eksen) karşı Yanlış Pozitif Değerlerin Oranını (Özgüllük) (y eksen) çizerek oluşturulur. ROC Eğrisi, Hassasiyet / Özgüllük (Sensitivity) raporu oluşturmaya yarar. ROC eğrisinin altındaki alan Area Under Curve (AUC) , bir parametrenin iki sınıf arasında ne kadar iyi ayırt edilebileceğinin bir ölçüsüdür. Şekil 4.2’de k-NN algoritması ROC eğrisi verilmiştir.




Şekil 4.2 : k-NN algoritması ROC eğrisi

Veri tabanımız rasgele işaretlerden oluştuğu için modelin performansını değerlendirmede ROC eğrisi idealdir. Auc eğrinin altında kalan alanı 0.87 oranında olup, bu sonuç k-NN modelinin sınıfları ayırt etmede ki başarısının değerini göstermektedir. Şekil 4.3’de SVM modelin Karışıklık Matrisi verilmiştir.



Şekil 4.3 : SVM algoritması karışıklık matrisi

Şekil 4.4’te SVM modelin ROC curve değeri 0.96 bulunduğu görülmektedir.



Şekil 4.4 : SVM algoritması ROC curve eğrisi

Veri setini aldığımız çalışma grubunun yayınladığı makaleye göre, EMG sinyalinden 8 özellik çıkarılmış ve yapılan 4 hareket içerisinde hassas tutuş hareketi değerlendirilmede yeterli verim alınmadığı için sonuçlara dahil edilmemiş olup; çalışma 3 el hareketi ile tamamlanmıştır. Öncelikle bu tez çalışmasında aynı 8 özellik kullanıldığında çok yakın doğruluk değerleri alındığı görülmüştür. Bunun üzerine benzer hareketlerde daha yüksek verimlilikte doğruluk değeri alınabilmesi amacıyla özellik sayısını 10'a çıkararak hareket sayısına da hassas tutuş hareketini ekleyip hareketi 4'e çıkararak, çalışma daha kapsamlı hale getirilmiştir. Yapılan çalışma 8 özellik ve 3 hareket ile %81,2 doğruluk değerini bulurken bu tez çalışmasında %87.6 doğruluk değerine ulaşılabilmiştir. Literatürde yapılan çalışmalarda daha farklı hareket çeşitleri kullanılmasına rağmen benzer veya daha düşük düzeylerde sonuçlar elde edildiği görülmüştür. Bağcı ve Koçal'ın yaptığı Biyonik el kontrolü sağlamak için EMG sinyallerinin makine öğrenmesi yöntemiyle sınıflandırılması çalışmasında 6 kadın ve erkek sağlıklı bireyden alınan, 6 farklı hareket ile yapılmış bu çalışmada k-NN modeli kullanılarak alınan değer %84.2 olduğu görülmüştür (Bağcı & Koçal, 2016). Çerçi ve Temeltaş'ın yaptığı EMG işaretlerinin özneliklerinin çıkarılması çalışmasında 8 kişiden alınmış 8 hareket sınıfı ile k-NN modeli kullanılarak %62 değerinde doğruluk tahmini alınmıştır (Çerçi, Çağrı, Hakan Temeltaş, 2017). Literatürde %90'ların üstünde doğruluk tahmini alınan çalışmalar bulunmaktadır ancak; bunlar kısıtlı katılımcı sayısı, el hareketleri veya belli sayıda öznelikten oluşmaktadır. Bu tez çalışmasında, yumruk (Fist) ve slindir kavrama (Cylindrical grasp) birbirine benzer hareketler olduğu için sınıflandırması zor hareketlerdir ancak; buna rağmen çıkarılan fazla sayıda öznelikler ile sınıflandırma değerinin performansının yüksek olmasına katkı sağlanmıştır.

Bu tez çalışmasında Makine öğrenmesi kısmından ayrı olarak Python'da test edilip eğitilen derin öğrenme modelinde en iyi %82 değerinde doğruluk tahmini alınmıştır. Burada Makine öğrenimi ile herhangi bir kıyaslama yapılmaksızın tamamen ayrı olarak denenmiş olan bu yöntemde verimli sonuç alınmamıştır. Test edilen ve eğitilen tahmin değerlerinin sonuçları ise Tablo 4.2'de verilmiştir.

Tablo 4.2 : Derin öğrenme kayıp ve doğruluk tahmini değerleri

Model	Kayıp (Eğitilen)	Doğruluk (Eğitilen)	Validasyon kayıbı (Test edilen )	Validasyon doğruluğu (Test edilen )
1.Sequential	0.2910	0.8843	0.7282	0.7700
2.Sequential	0.4500	0.8300	0.62	0.82

Tablo 4.2’de verilen Model 1 eğitim ve test değerleri verilerin ilk eğitildiği modelde ki değerlerinden alınan sonuçlar olup %77 civarında olduğu görülmüştür. Buradan hareketle, sınıflandırmada daha yüksek bir doğruluk almak adına Epoch ve Dense ve Batch Size değerlerinde değişiklik yapılarak ikinci eğitim ile Model 2’de daha iyi doğruluk değeri alınmıştır. Kullandığımız alternatif Derin öğrenme algoritmaları yüksek veri seti ile çalışılmaya uygun olduğu için bu çalışmada derin öğrenmede iyi bir performans elde edilmemesi bir yorum olarak sunulmaktadır.

## **BÖLÜM 5. DEĞERLENDİRME**

Bu tez çalışmasında, EMG sinyallerinin benzer el hareketlerine göre sınıflandırılması hedeflenmiştir. Bu doğrultuda denenen birçok makine öğrenmesi algoritmalarının içerisinde Fine k-NN algoritmasında sınıflandırıcı performansının %87.6 ile diğerlerine göre daha yüksek değere ulaştığı tespit edilmiştir. Deneylerde gerçekleştirilen el hareketleri birbirine benzer olmasına rağmen elde edilen doğruluk değerinin yüksek olduğu görülmüştür. Literatürde benzer çalışmalar bulmak mümkün olsada bu çalışmaların çoğunda veri tabanı özellikleri detaylandırılmamış olup; kısıtlı sayıda katılımcı ile tek bir algoritma üzerinden değerlendirme yapılmıştır. Kullandığım makalede 225 katılımcıdan elde edilen verilerle yapılan bu çalışmada öz nitelikler artırılmış ve Makine Öğreniminde algoritmaların veri seti üzerinde kıyaslamaları yapılmıştır. Kullanılan katılımcıların verilerine, cinsiyetlerine, özelliklerin seçilmesine ve çıkarılmasına bağlı olarak hesaplama sürelerinden tasarruf edilmesinin yanı sıra algoritma performanslarındaki iyileşmeler de gelecek çalışmalar için belirleyici bir etken olmuştur. Aynı veri seti ile yapılan çalışmadan elde edilen %81,2'lik doğruluk değeriyle bile robotic bir el kontrolünün sağlanabileceği gösterildiği için, bu tez çalışmasında kullanılan yöntemle bulunan daha iyi doğruluk performans değerinin kontrol çalışmalarında daha başarılı sonuçlar elde edilebileceği öngörülmüştür.

## KAYNAKLAR

- A. Chaudhary, R. (2018). *Hand Gesture Recognition for Robotic Hand Control*. Springer.
- A. Prof, M. T. and P. P. K. (2014). A. Prof, M. Tafhim and P. P. Kshirsagar, A Review on EMG Signal 54 Classification for neurological disorder using neural network, *IOSR J. Elect. Electro. Eng.*, (2014) 21–23.
- Abreu, J. G., Teixeira, J. M., Figueiredo, L. S., ve Teichrieb, V. (2016). “Evaluating Sign Language Recognition Using the Myo Armband”, *Proceedings - 18th Symposium On Virtual And Augmented Reality, SVR 2016*, 64–70 (2016).
- Arief, Z., Sulistijono, I. A., ve Ardiansyah, R. A. (2015). “Comparison of Five Time Series EMG Features myo armband”, *International Electronics Symposium*, 11–14 (2015).
- B. De la Cruz-S´anchez, M. Arias-Montiel, and E. Lugo-Gonz´alez. (2019). *sEMG database of the MYO bracelet for hand gestures*. Mendeley Data, 2019. <https://data.mendeley.com/datasets/rwbs7645hg/1>
- Bağcı, D., & Koçal, O. H. (2016). *Protez-Biyonik El Kontrolü İçin EMG İşaretlerinin Makine Öğrenmesi Metodlarıyla Sınıflandırılması*.
- Basmajian, J.V. ve de Luca, C. J. (1985). *Muscles Alive - The Functions Revealed by Electromyography*. The Williams & Wilkins Company; Baltimore.
- Basmajian, J.V. ve de Luca, C. J. (1985). (n.d.). *Use of Surface Electromyography in Biomechanics*. *Journal of Applied Biomechanics*, 13, 135-163.
- Brownlee, J. (2020). *Why Use Ensemble Learning?* <https://machinelearningmastery.com/why-use-ensemble-learning/>.

- Çalışkan, A. (2019). EmSinyalleriİçİHibriÖznitelik ÇıkarmaYönteGeliştirilmesi. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 8(2), 652–664. <https://doi.org/10.28948/ngumuh.542973>
- Castellini, C., van der Smagt, P., Sandini, G. ve Hirzinger, G. (2008). *Surface EMG for force control of mechanical hands*, in: *Proceedings of the IEEE International Conference on Robotics and Automation, Pasadena, CA, USA*, pp. 725–730.
- ÇERÇİ, Çağrı ,Hakan TEMELTAŞ. (2017). *EMG İŞARETLERİNİN ÖZİNİTELİKLERİNİN ÇIKARILMASI, KNN VE YSA YÖNTEMLERİ İLE SINIFLANDIRILMASI*.
- deeplearning. (2020). <https://stackabuse.com/deep-learning-in-keras-building-a-deep-learning-model/>.
- Deng, Li, Liu, Y. (2018). *Deep Learning in Natural Language Processing*.
- Dr. Carlo J. De Luca\*. (2014). *Imaging the Behavior of Motor Units by Decomposition of the EMG Signal*. [http://www.delsys.com/Attachments\\_pdf/EMG%20Decomposition%20Presentat%20i%20on.pdf](http://www.delsys.com/Attachments_pdf/EMG%20Decomposition%20Presentat%20i%20on.pdf), 16.04.2014.
- Ejderha, H. (2009). . “EMG işaretlerin kullanılarak yorgunluk seviyelerinin neurofuzzy ve YSA ile siniflandırılması, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahraman Maraş.
- Github. (2020). [https://maelfabien.github.io/machinelearning/ml\\_base/#](https://maelfabien.github.io/machinelearning/ml_base/#).
- Güler, İ. (2015). *Güler, İ. (2005). Biyomedikal Enstrümantasyon. Nadir Kitap*.
- Güvenç, S. A. (2014). *DENÖN KOL YÜZEY EMG SİNYALLERİNİN ÖRÜNTÜ TANIMA TABANLI ANALİZİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI*.
- H., M. C. D. and S. (1999). *Foundations of Statistical Natural Language Processing [M] Cambridge: Mit Press*.
- Huang, H.-P. ve Chen, C.-Y. (1999). *Development of a myoelectric discrimination system for a multi-degree prosthetic hand,” in Robotics and Automation, 1999. Proceedings. of International Conference on Robotics and Automation, vol. 3*.



*IEEE*, 2392–2397.

Hudgins, B., Parker, P., and Scott, R. N. (1993). *A New Strategy for Multifunction Myoelectric Control*. *Ieee Transactions on Biomedical Engineering*, . 40(1): p. 82-94.

Jaramillo-Yáñez, A., Benalcázar, M. E., & Mena-Maldonado, E. (2020). Real-time hand gesture recognition using surface electromyography and machine learning: A systematic literature review. *Sensors (Switzerland)*, 20(9), 1–36. <https://doi.org/10.3390/s20092467>

Joshi, D., Kandpal, K. ve Anand, S. (2008). *Feature evaluation to reduce false triggering in threshold based emg prosthetic hand*. in *4th Kuala Lumpur International Conference on Biomedical Engineering 2008. IFMBE Proceedings*, N. A. Abu Osman, F. Ibrahim, W. A. B.

K., Ş. (2007). Şenli K., 2007. “EMG (Elektromiyografi) Kontrollü Protez Kol Tasarımı”, *Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri*.

Kaggle, Erişim: 18 Mayıs 2021, <https://www.kaggle.com/dansbecker/rectified-linear-units-relu-in-deep-learning>.

Karla Dhungana Sainju, Niti Mishra, Akosua Kuffour, L. Y. (2021). *An examination of bully-related tweets using supervised machine learning*. *Computers in Human Behavior* 120,.

Khushaba, R. N., Kodagoda, S., Takruri, M., Dissanayake, G. (2012). *Khushaba, R. N., Kodagoda, S., Takruri, M., Dissanayake, G. “Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals” in Elsevier, Expert Systems with Applications 39 sf. 10731- 10738.*

Konard, P. (2012). *The ABC of EMG*. *Noraxon: Scottsdale, April*, 1–60. <http://www.demotu.org/aulas/ABCofEMG.pdf>.

Küçük yıldız, G., Ocak, H., Şayli, Ö., ve Karakaya, S. (2015). “*Engelliler için EMG Tabanlı Kinect Destekli Bir Tekerlekli Sandalyenin Gerçek Zamanlı Kontrolü (Real Time Control of a WheelChair based on EMG and Kinect for the Disabled People)*”, *Tıp Teknolojileri Ulusal Kongresi (TIPTEKNO) 2015*, 424–427 (2015).

- Küçük yıldız, G., Ocak, H., Şaylı, Ö., ve Karakaya, S. (2015). , “Engelliler için EMG Tabanlı Kinect Destekli Bir Tekerlekli Sandalyenin Gerçek Zamanlı Kontrolü (Real Time Control of a WheelChair based on EMG and Kinect for the Disabled People)”, *Tıp Teknolojileri Ulusal Kongresi (TIPTEKNO) 2015*, 424–427.
- L.J Myers ve diğerleri. (2003). *Rectification and non-linear pre-processing of EMG signals for cortico-muscular analysis, Journal of Neuroscience Methods, Volume 124, Issue 2, Pages 157-165, ISSN 0165-0270, [https://doi.org/10.1016/S0165-0270\(03\)00004-9](https://doi.org/10.1016/S0165-0270(03)00004-9). (<https://www.sciencedirect.com/sc>.*
- Lucas, M.F., Gaufriau, A., Pascual, S., Doncarli, C., Farina, D. (2008). *Multi-Channel Surface EMG Classification Using Support Vector Machines and Signal-Based Wavelet Optimization Machines and Signal-Based Wavelet Optimization. Biomedical Signal Processing and Control.*
- M. A. Oskoei and H. Hu. (2008). “Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb,” in *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 8, pp. 1956-1965, Aug. , doi: 10.1109/TBME.2008.919734.
- Masso, N., Rey, F., Romero, D., Gual, G., Costa, L. ve German, A. (2010). *Surface Electromyography and Applications in Sport. Apunts Medicina De L’Esport*, 45 (166), 121-130.
- N. Rabin, M. Kahlon, S. Malayev, and A. R. (2020). “Classification of human hand movements based on EMG signals using nonlinear dimensionality reduction and data fusion techniques,” 2020.
- Navlani, A. (2019). *Support Vector Machines with Scikit-learn.* <https://www.datacamp.com/community/tutorials/svm-classification-scikit-learn-python>.
- Oppermann, A. (2019). *What is Deep Learning and How does it work?* <https://towardsdatascience.com/what-is-deep-learning-and-how-does-it-work-2ce44bb692ac>.

- Özmen. (2013). *Servikal Bölgede Oluşan Kas Yorgunluğunun Yüzey Elektromiyogram Bilgileri İle Değerlendirilmesi. (Yüksek Lisans Tezi). Selçuk Üniversitesi Fen Bilimleri Enstitüsü.*
- Özyener. (2014). Özyener, F., *Fizyoloji Ders Notları-Egzersize Kas Sisteminin Yanıtı.* <http://tip.uludag.edu.tr/temel-tip-bilimleri/fizyoloji/ders-notlari/cizgili-kaskasilma-mekanizmasi.pdf> 15.04.2014.
- Phinyomark, A., Limsakul, C. ve Phukpattaranont, P. (2009). *A novel feature extraction for robust emg pattern recognition,” Journal of Computing, 1 (1), 71–80.*
- Rahime Yılmaz, Y. D. D. T. E., & Arslan, D. D. Y. Z. (2017). *İnsan Elinin Pozisyon Ve Kuvvetlerinin Kestirimi Amacıyla Emg Sinyallerinin Sınıflandırılması.*
- Raschka, S. (2014). *Linear Discriminant Analysis.* [https://sebastianraschka.com/Articles/2014\\_python\\_lda.html](https://sebastianraschka.com/Articles/2014_python_lda.html).
- Reaz MB, Hussain MS, M.-Y. F. (2006). *Techniques of EMG signal analysis: detection, processing, classification and applications (Correction). Biol Proced Online. ;8:163. doi: 10.1251/bpo124. Erratum for: Biol Proced Online. 8:11. PMID: 19565309; PMCID: PMC1622762.*
- S. A. Ahmad and P. H. Chappell. (2007). *“Surface EMG classification using moving approximate entropy,” 2007 International Conference on Intelligent and Advanced Systems, 2007, pp. 1163-1167, doi: 10.1109/ICIAS.2007.4658567.*
- Sadhukhan, A. K., Goswami, A., Kumar, A., & Gupta, S. (1994). Effect of sampling frequency on EMG power spectral characteristics. *Electromyography and Clinical Neurophysiology, 34(3), 159–163.*
- Şenli, K. (2011). *Emg (Elektromiyografi ) Kontrollü Protez Kol Tasarımı. Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.*
- Thalmic Lab. (2020). <https://developerblog.myo.com/myoarm-resim-Thalmics-Myo-Armband-Web-Page>".
- Togawa, T., Tamura, T. ve Oberg. (1997). *Togawa, T., Tamura, T. ve Oberg, P. A. (1997). Biomedical Transducers and Instruments. New York: CRC Press.*

- Tsinganos, P., Cornelis, B., Cornelis, J., Jansen, B., & Skodras, A. (2018). Deep learning in EMG-based gesture recognition. *PhyCS 2018 - Proceedings of the 5th International Conference on Physiological Computing Systems, September*, 107–114. <https://doi.org/10.5220/0006960201070114>
- Tygar, J. D. (2011). *Adversarial Machine Learning*. in *IEEE Internet Computing*, 15 (5), 4-6.
- Wang, Y., Xiang, J., Markert, R. ve Liang, M. (2016). *Spectral kurtosis for fault detection, diagnosis and prognostics of rotating machines: A review with applications*. *Mechanical Systems and Signal Processing*, 66, 679–698.
- Wannous, H., Lucas, Y., & Treuillet, S. (2008). Efficient SVM classifier based on color and texture region features for wound tissue images. *Medical Imaging 2008: Computer-Aided Diagnosis*, 6915, 69152T. <https://doi.org/10.1117/12.770339>
- Webster, John G., 1978, *Medical Instrumentation, Applications and Design*. (1978). John G.
- Xoriant. (2017). *Decision Trees for Classification: A Machine Learning Algorithm*. <https://www.xoriant.com/blog/product-engineering/decision-trees-machine-learning-algorithm.html>.
- Zardoshti-Kermani, M., et al. (1995). *EMG feature evaluation for movement control of upper extremity prostheses*. *IEEE Transactions on Rehabilitation Engineering*, 3(4): p. 324-333.
- Zhang, Y., Liu, B., Ji, X., & Huang, D. (2001). *Classification of EEG Signals Based on Autoregressive Model and Wavelet Packet Decomposition*. *Neural Processing Letters*, 45(2), 365–378. <https://doi.org/10.1007/s11063-016-9530-1>.
- Zhang, Y., Liu, B., Ji, X., & Huang, D. (2017). *Classification of EEG Signals Based on Autoregressive Model and Wavelet Packet Decomposition*. *Neural Processing Letters*, 45(2), 365–378. <https://doi.org/10.1007/s11063-016-9530-1>