

YALOVA ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**BİYONİK EL KONTROLÜ İÇİN EMG İŞARETLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMİYLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Duygu BAĞCI

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

HAZİRAN 2016

YALOVA ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**BİYONİK EL KONTROLÜ İÇİN EMG İŞARETLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMİYLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

**Duygu BAĞCI
(125105002)**

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Yrd. Doç. Dr. Osman Hilmi KOÇAL

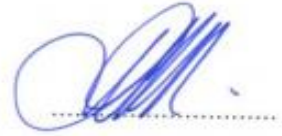
HAZİRAN 2016

YALOVA Üniversitesi Fen Bilimleri Enstitüsü'nün 125105002 numaralı Yüksek Lisans Öğrencisi **Duygu BAĞCI**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ **BİYONİK EL KONTROLÜ İÇİN EMG İŞARETLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMİYLE SINIFLANDIRILMASI**” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : Yrd. Doç. Dr. Osman Hilmi KOÇAL
Yalova Üniversitesi



Jüri Üyeleri : Yrd. Doç. Dr. Osman Hilmi KOÇAL
Yalova Üniversitesi



Doç. Dr. Müfit ÇETİN
Yalova Üniversitesi



Yrd. Doç. Dr. Emrah YÜRÜKLÜ
Bursa Orhangazi Üniversitesi



Teslim Tarihi : 13 Mayıs 2016
Savunma Tarihi : 17 Haziran 2016





Kız kardeşim Selin'e ve çok değerli aileme,



ÖNSÖZ

Tez çalışmam süresince bana akademik deneyim ve olgunluğu ile yol gösteren, tevazu sahibi kişiliğiyle motivasyonumu eksiltmeyen çok değerli hocam Sayın Yrd. Doç. Dr. Osman Hilmi KOÇAL'a, bu tez çalışmasına ilham veren değerli bölüm arkadaşım Uzm. Uğur TURHAL'a, her zaman destekleriyle yanımda olan kıymetli meslektaşım Öğr.Gör. Oğuzhan DAŞ'a teşekkürlerimi sunarım.

Haziran 2016

Duygu BAĞCI
Öğretim Görevlisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET.....	xvii
SUMMARY	xix
1. GİRİŞ	1
1.1.Tezin Amacı	1
1.2.Literatür Araştırması	3
2. GENEL BİLGİLER.....	5
2.1.Kas Sistemi.....	5
2.1.1. Kasların Yapısı.....	5
2.1.2 Kasların İşlevleri	6
2.1.3 Kas türleri.....	7
2.1.4 Aksiyon Potansiyeli	7
2.2.Elektromiyografi	8
2.2.1. Elektromiyografi Çeşitleri.....	10
2.2.2. Elektromyogramın Teknik Kısımları	12
2.2.3. Motor Birim ve Motor Ünite Aksiyon Potansiyeli (MÜAP)	14
2.3.EMG İşaretleri Analizi (Modelleme , zaman, frekans domeni,gürültü)	15
3.BİYOMEDİKAL İŞARET İŞLEME	19
3.1.Rasgele İşaretlerin İşlenmesi.....	19
3.1.1.Stokastik süreç ve Markov modeli.....	19
3.1.2.Dalgacık analizi ve dalgacık türleri	24
4. MAKİNE ÖĞRENMESİ.....	39
4.1 Gözetimli Öğrenme	41
4.1.1 Lineer regresyon	41
4.1.2 Lojistik regresyon	42
4.1.3 Destek vektör makineleri	42
4.1.4 En yakın k komşu algoritması(k-NN).....	43
4.1.5. Karar ağaçları	44
4.1.6 Çok katmanlı yapay sinir ağları	45
4.1.7 Naive Bayes Sınıflandırma Algoritması(NB).....	46
5. MATERYEL VE METOD	47
6. BULGULAR	55
7. SONUÇLAR VE ÖNERİLER	59
KAYNAKLARIM	65
ÖZGEÇMİŞ.....	69
TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR	69

KISALTMALAR

ADD	: Ayrık Dalgacık Dönüşümü
Knn	: K en yakın komşu algoritması
db	: Daubechies dalgacığı
AR	: Otoregresif model
ARMA	: Otoregresif hareketli ortalamalar modeli
ARIMA	: Otoregresif bütünleşik hareketli ortalamalar modeli
MUAP	: Motor ünite aksiyon potansiyeli
YSA	: Yapay sinir ağları
GMM	: Gizli Markov modeli
DVM	: Destek vektör makineleri



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1 : Stokastik süreçlerde sınıflandırma.....	18
Çizelge 3.2 : Fourier dönüşümü ve Dalgacık dönüşümü gösterimler.....	22
Çizelge 4.1 : Çeşitli uzaklık fonksiyonları ve gösterimleri.....	38
Çizelge 6.1 : Markov geçiş matrisi elemanlarından oluşan öznitelik vektörlerinin sınıflandırma sonuçları.....	49
Çizelge 6.2 : Daubechies dalgacık ailesinin farklı tipleri ile elde edilen katsayılara ait öznitelik vektörlerinin sınıflandırma sonuçları.....	49
Çizelge 6.3 : Db8 dalgacığı farklı levellerde ayrıştırılarak elde edilen katsayılara ait öznitelik vektörlerinin sınıflandırma sonuçları.....	50
Çizelge 6.4 : Ayrık dalgacık dönüşümü analizi ile db8 dalgacığının 7 level ayrıştırma sonucu elde edilen katsayılara ait öznitelik vektörlerinin farklı algoritmalarla sınıflandırma sonuçları.....	50
Çizelge 6.5 : Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşüm katsayıları birlikte kullanılarak oluşturulan öznitelik vektörlerinin KNN algoritması ile farklı n değerlerinde sınıflandırma sonuçları(db8 level7).....	50
Çizelge 6.6 : Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşüm katsayıları birlikte kullanılarak oluşturulan öznitelik vektörlerinin çeşitli algoritmalarla sınıflandırma sonuçları(db8 level7).....	51
Çizelge 6.7 : Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşümü katsayılarının ayrı ve birlikte çeşitli algoritmalarla sınıflandırma sonuçları(KNN için n=1).....	51
Çizelge 6.8 : Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşümü katsayılarının ayrı ve birlikte çeşitli algoritmalarla sınıflandırma sonuçları(KNN için n=3).....	51
Çizelge 6.9 : CfsSubsetEval ile öznitelik indirgeme işleminden sonra çeşitli algoritmalar için sınıflandırma sonuçları(KNN için n=1).	51
Çizelge 6.10 : CfsSubsetEval ile öznitelik indirgeme işleminden sonra çeşitli algoritmalar için sınıflandırma sonuçları(KNN için n=3).....	52



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: İskelet kasının yapısı.....	5
Şekil 2.2: Farklı kas türlerinin mikroskopik görüntüleri	6
Şekil 2.3: Aksiyon potansiyeli oluşumu.	8
Şekil 2.4: Örnek EMG Sinyali Güç ve Frekans Grafiği.	9
Şekil 2.5: Yüzeylektrot çeşitleri.	10
Şekil 2.6: İğne elektrot çeşitleri.	11
Şekil 2.7: Yüzeylektrot ve İğne Elektrot ile Yapılan Ölçümlerin Karşılaştırılması	11
Şekil 2.8: Standart Bir EMG Sisteminin Bileşenleri.	13
Şekil 2.9: EMG, EEG ve EKG sistemlerinin frekans ve voltaj aralıklarındaki çalışma durumları.	13
Şekil 2.10: Motor birim aksiyon potansiyeli.	14
Şekil 2.11: MUAP dizileri.	15
Şekil 2.12: İntegratörün çeşitli noktalarındaki işaretlerin zamana göre değişimi	16
Şekil 2.13: EMG işaretlerinin elektrotta ulaşınca kadar geçtiği işlemler	16
Şekil 2.14: İdealize edilmiş EMG işareti güç spectrum yoğunluğu	17
Şekil 3.1: Örnek bir rastgele süreç gösterimi.	17
Şekil 3.2: Örnek bir rastgele süreç gösterimi-2.....	19
Şekil 3.3: Durağan bir sinüs fonksiyonunun Hanning pencere fonksiyonu uygulanmadan önceki ve sonraki görünümü.	19
Şekil 3.4: Fourier dönüşümü ve KSFĐ temsili çözünürlük farkları.	21
Şekil 3.5: Çoklu çözünürlük gösterimi.	22
Şekil 3.6: $f_j(x)$ sinyalinin yüksek geçişli ve alçak geçişli filtrelerden geçirilip farklı çözünürlük kademeleri için bir katsayı oluşturması.	23
Şekil 3.7: Bir sinyalin Haar dalgacığı ile 3 kademe ayrıştırılması	25
Şekil 3.8: Daubechies 4 dalgacığının 3. ölçekteki görünümü.	25
Şekil 3.9: Daubechies 4 dalgacığının 3. Ölçekte örnek sinyal üzerinde ötelenmesi.	25
Şekil 3.10: Ayrıştırma işlemi.	27
Şekil 3.11: Örnek sinyal.	27
Şekil 3.12: Örnek sinyalin sürekli ve ayrık dönüşümleri.	28
Şekil 3.13: Dalgacıkların genel sınıflandırılması.	28
Şekil 3.14: Farklı dalgacık ailelerine ait örnekler.	29
Şekil 3.15: Haar ölçek ve dalgacık fonksiyonları.	30
Şekil 3.16: Daubechies 3(a) Ölçeklendirme fonksiyonu, (b) Dalgacık fonksiyonu.	31
Şekil 3.17: Symlet 3(a) Ölçeklendirme fonksiyonu, (b) Dalgacık fonksiyonu.	32
Şekil 3.18: Morlet dalgacık fonksiyonu.	32
Şekil 3.19: Mexican Hat dalgacığı.	33
Şekil 3.20: Meyer 3(a) Ölçeklendirme fonksiyonu, (b) Dalgacık fonksiyonu.	34
Şekil 4.1: Verinin bilgiye dönüşüm süreci	35
Şekil 4.2: Gözetimli/gözetimsiz öğrenme metodlarının örnek gösterimleri.	36
Şekil 4.3: Standart lojistik fonksiyonu grafiği.	37
Şekil 4.4: Lineer olarak ayrılabilen ve ayrılamayan verilerin gösterimi.	38

Şelik 4.5: Örnek Knn sınıflandırması gösterimi.	39
Şekil 4.6: Çok katmanlı yapay sinir ağı örneği.	40
Şekil 5.1: Ön kol kaslarının anatomisi.	42
Şekil 5.2: Silindirik hareket için 1.kanaldan alınan kayıt örneği.	42
Şekil 5.3: Veri setindeki 6 temel hareket.	43
Şekil 5.4: Küresel hareket için 2 kanaldan kaydedilen örnek EMG sinyali.	43
Şekil 5.5: Uç hareket için 2 kanaldan kaydedilen örnek EMG sinyali.	44
Şekil 5.6: Palmar hareket için 2 kanaldan kaydedilen örnek EMG sinyali. ...	44
Şekil 5.7: Lateral hareket için 2 kanaldan kaydedilen örnek EMG sinyali. ...	45
Şekil 5.8: Silindirik hareket için 2. kanaldan kaydedilen örnek EMG sinyali.....	45
Şekil 5.9: Kanca hareket için 2 kanaldan kaydedilen örnek EMG sinyali.	46
Şekil 5.10: Çalışmanın işlem basamakları.	46
Şekil 5.11: Dataset ekran görüntüsü.	47
Şekil 5.12: WEKA Programından bir arayüz görüntüsü.	48
Şekil 5.13: Özniteliklerin sınıf verileriyle ilişkisini gösteren WEKA görüntüsü.	48



BİYONİK EL KONTROLÜ İÇİN ELEKTROMİYOGRAF İŞARETLERİNİN DALGACIK DÖNÜŞÜMÜ VE MAKİNE ÖĞRENMESİ METODLARIYLA SINIFLANDIRILMASI

ÖZET

Günümüzde kullanılmakta olan çok işlevli protez-biyonik kolların hareket yeteneği birkaç hareketle sınırlıdır. Protez-biyonik ellerin işlevselliğini arttırmak için araştırmacılar üç farklı koldan çalışmaktadır. Bunlar mekanik aksamın tasarımını geliştirip sistemin serbestlik derecesini arttırarak hareket yeteneğinin iyileştirilmesi, elektronik aksamın geliştirilerek istenilen rotasyonda ve hızda hareket etmesinin sağlanması ve kaynak işaretleri olan EMG sinyallerinin analiz edilmesi olarak ifade edilebilir. Sinyallerin hedef hareketi temsil edecek şekilde analiz edilmesi ilerleyen bölümde açıklanacağı gibi sistemin performans verimliliği ve sınıflandırma verimliliği açısından hayatidir. Mekanik ve elektronik aksamın gelişmesi de teknolojik/bilimsel gelişmelerle paralellik gösterse de EMG sinyal analizi işlemlerinin gelişmesi sinyal işleme ve makine öğrenmesi metodlarındaki güçlü gelişmelerle sistem performansını etkileyen en önemli ana kolunu taşımaktadır. Sinyaldeki gürültülerden arındırmak için frekans band genişliğinin yüksek tutulması sinyalin bütünlüğünü bozan detayların dahil edeceği gibi düşük tutulması ise sinyal için önemli olan detayların kaybolarak karakteristiğinin bozulmasına neden olabilir. Bu yüzden doğru sinyal analizi için akıllı algoritmaların kullanılması şarttır.

EEG sinyalleri de kaynak işaretine alternatif olabilir. Fakat EEG sinyalleri daha düşük band genişliğine sahip olmakla birlikte daha düşük genliğe sahip olduğu için gerçek hayatta EMG sinyallerine göre daha çok gürültüye karışmaları verimi düşmektedir. Bu anlamda EMG sinyallerinin kaynak işareti olarak kullanılması daha makul görünmektedir.

EMG sinyalinin karakteristik kestiriminde Dalgacık Dönüşümü analizinin sıklıkla kullanıldığı bilinmektedir. Bu çalışma kapsamında EMG sinyallerinin temsil

yeteneđi en yksek olan dalgacık tipi ve ayrıştırma derecesi kestirilmeye alıřılmıştır. Bununla beraber daha verimli bir sınıflandırma hangi metodla yapılır sorusuna yanıt aranmıştır. Protez-biyonik ellerin işlevselliđini arttırmak amacıyla gndelik hayatta nesnelere tutmaya/kavramaya yarayan ve sıklıkla kullanılan 6 temel el hareketine ait EMG sinyallerinden oluřan 900 rnek veriliř bir veri seti kullanılmıştır. EMG sinyallerine ait temsil yeteneđi en gçl olan znelik vektrn elde etmek iin Markov geiř matrisi elemanları ve Ayrık Dalgacık Dnřm analizi kullanılmıştır. Elde edilen znelik vektrne eřitli makine đrenmesi algoritmalarıyla sınıflandırma performans analizleri uygulanmıştır.

alıřma kapsamında kullanılan metodlar ile elde edilen sonular uluslar arası alanda yapılan benzer alıřmalarla paralel ve anlamlı sonular tařımanın yanında hız performans dengesi ile gerek zamanlı kullanılabilirlik konusunda tercih edilebilirliđini arttırmıştır.

Verimli bir EMG sinyali karakteristik kestirimi protez-biyonik kolların geliřtirilmesine yardımcı olmasının yanında robot kolların geređe uygun geliřtirilmesinde, kesik uzuvların yerine dikilmesinde veya klinik teřhislerin belirlenmesine de yardımcı olması beklenmektedir. Bu alıřma da kullanılan metodlarla EMG sinyallerinin karakteristik kestirimini ve sınıflandırma bařarısını ve performansını artmasına katkı sađlanmaya alıřılmıştır . Elde edilen sonular ve nerilen metodların yeni alıřmalara katkı sađlayacađı dřnlmektedir.

WAVELET TRANSFORMATION AND CLASSIFICATION WITH MACHINE LEARNING METHODS OF ELECTROMYOGRAPHY SIGNALS FOR BIONIC HAND CONTROL

SUMMARY

Multi functional prothesis bionic arms/hand are limited in term of motion. To improve those prothesis functionality reserarchers are studying in many ways. Those are enhancig the ability of motion, providing the desired rotation and the motion by improving electronical parts and analyzing EMG signals that are source signals. It is crucial for efficiency of classification and system's performance that analyzing of signals should represent the aimed motion. Developments in signal analysis procedures of EMG and machine learning methods are the most important factors that effects system's performance. Selecting high frequency bands or low frequency bands in order to clear disturbance may deflect characteristics. So that if is important to analyze signals correctly smart algorithms should be used.

EEG signals can be used as alternative to source signals. But EEG signals have lower bandwith and lower amplitude. So, they can be defected harder when compared with EMG.

It is known that Wavelet Transformation Analysis is using widely to estimate characteristics of EMG signals. In this study, it has been focused on decomposition degree and prediction of wavelet that is the most representative property of EMG signals. In addition, the question of which method should be used for creating more efficient classification. 900 data set that belongs to EMG signals of 6 basic hand motions which are usually used for holding/grabbing has been used in order to improve the functionality of prothesis hands. Split Wavelet Transform and Markov Transformation Martix have been used to onlain vector of attribute that is the most representative speciality of EMG signals. Performance analyses have been performed to vector of attribute by using various algorithms of machine learning methods.

When comparing with other worldwide studies, it is seen that the results of this study, are accurate, more over, it is more preferable in terms of real-time usage, beacuse of the stability between speed and performance.

In addition to help developing prothesis-bionic hand/arms, it is expected that prediction of the characteristics of an efficient EMG signal will be able to help designing the prothesis more accurate, stiching body parts and identicating clinical diagnosis. By methods that have been used in this study, improvement of prediction of characteristics of EMG signals and performance is expected. All obtained results and suggested methods may contribute to new studies.



1. GİRİŞ

1.1. Tezin Amacı

EMG (Elektromiyogram) kas sinyallerinin ölçümünü yapan medikal bir sistemdir. Bir kasın hareketi sırasında biyoelektriksel bir sinyal ortaya çıkar. EMG sinyalleri kas ve sinir hastalıklarının tedavisinde, çizgili kas içeren zayıf uzuvların güçlendirilmesinde, fizik tedavi-rehabilitasyon çalışmalarında kullanıldığı gibi ampüte uzuvların yerine eklenmesinde ve biyomühendislik çalışmalarında protez uzuvların geliştirilmesinde de kaynak işareti olarak kullanılmaktadır. Son yıllarda bu alanda yapılan çalışmaların artmasıyla paralel olarak geliştirilen modellerin verimliliği de artmış olsa da halen maliyet, üretim, gerçek zamanlı çalışabilme yeterliliği, kısıtlı hareket desteği gibi sorunlara daha tatminkar çözümler üretme çabası araştırmacıları yeni yöntemler geliştirmeye yöneltmektedir. Bu tez çalışması ile günlük hayatta kullanılan temel el hareketlerine ait işaretlerin sınıflandırma başarısı artırılarak biyonomik el geliştirme çalışmalarına katkı sağlamak amaçlanmıştır. Sınıflandırma verimliliğinin artırılması klinik uygulamalarda kas hastalıklarının tespitine ve protez organ geliştirme başarımını arttırmada da dolaylı olarak katkı sağlayacak gelişmeleri beraberinde getirecektir.

Biyolojik işaretlerin karmaşık ve kompleks yapısı matematiksel olarak modellenmesini zorlaştıran bir unsurdur. Buna karşın son yıllarda geliştirilen algoritma ve modeller biyolojik sinyallerin daha verimli ve başarılı sınıflandırılmasına neden olmuştur. EMG sinyalinin dinamik karakteristiklerin kesinliğini geliştirmek için sinyalin matematiksel modelini oluşturmaya yönelik ilgi son yıllarda da devam etmektedir. Yüzey elektrotları veya iğne elektrotlar aracılığı ile ölçümlenen bu sinyaller düşük genliğe sahip oldukları için gürültülerden çok çabuk etkilenebilmektedir. Bu nedenle söz konusu sinyallerle çalışılırken gürültü faktörü iyi analiz edilmeli, sinyal gürültüden arındırılarak sonraki işlemler yapılmalıdır.

El hareketi ile önkol kaslarının hareketi arasında güçlü bir ilişki olduğu iyi bilinmektedir. EMG sinyali kasların hareketini kontrol etmek için insanın sinir sisteminden gönderilen bilgiyi içerir ve EMG sinyalinin gücü el hareketinin niteliğini yansıttığı yapılan çalışmalarda görülmektedir. Ancak EMG işaretleri rastgele işaretlerdir. Rastgele işaretler işlenmesi zor olup, durağan (stasyoner) ve durağan olmayan işaretler olarak ikiye ayrılır. Durağan olmayan işaretler için işlem yöntemleri pek etkili olmadığından durağan olmayan işaret, her biri durağan sayılan dilimlere (segmentlere) ayrılır. Bu anlamda segmentlerin rassal olduğu için bağımsız değişken özelliği gösterdiğini söyleyebiliriz. Bu bağımsızlık özelliği söz konusu sinyallerin analizinde kullanılan metodların tercihini de doğrudan etkilemektedir.

EMG işaretlerinin karakteristik özelliklerinin gruplanması için sezgisel yaklaşım, belirgin yaklaşım, istatistiksel yaklaşım, yapay sinir ağları yaklaşımı ve bulanık yaklaşım gibi birçok hesaplama yöntemi kullanılmış, bu algoritmaların başarısını artırmak için yardımcı ön işleme yöntemleri uygulanmıştır. Zaman domeni öznitelikleri, özbağlanım (AR) katsayıları, cepstral katsayılar bunlardan bazılarıdır.

Çalışmanın bu bölümünde problemin çerçevesi, çözüm için motivasyon yaratan konular, çalışmanın özgün değeri, konu hakkında genel bilgiler değinilmiştir. Aşağıda ise literatür çalışmaları aktarılmıştır.

Bir sonraki bölümde kas sistemi üzerine bilgiler aktarılmaktadır. Kasların yapısı, çalışma prensibi, aksiyon potansiyeli, Elektromiyogram yapısı, Motor Ünite Aksiyon Potansiyeli konularına değinilmektedir. 3. Bölümde Biyomedikal İşaret İşleme özelinde Rasgele işaretlerin işleme yöntemlerinden genel çerçevede söz edilmektedir. Bu başlık altında Fourier Dönüşümü, Dalgacık Analizi ve Durağan süreçler/ modeller üzerinde detaylandırmalar yapılmıştır. 4. Bölümde Makine Öğrenmesi başlığı altında gözetimli öğrenme ve gözetimsiz öğrenme süreçleri / algoritmaları açıklanmıştır. 5. Bölümde Metaryeller ve metodlar detaylandırılmış; veri setimizin karakteristik özelliklerinden bahsedilmiştir. Metodlar aktarılırken veri setimize uygulanan ön işlemler, boyut indirgeme algoritmaları, makine öğrenmesi algoritmalarına değinilmiştir.

1.2. Literatür Araştırması

[1, 2]'de sEMG sinyalinde zaman serisi verileri modeli oluşturmak için gizli Markov modeline dayalı yeni bir yinelemeli sinir ağı kullanıldı. [3, 4,5] 'te benzer teknikler kullanılmakla birlikte gizli Markov modeli sEMG sinyalinin fizyolojik olarak meydana getirilmesinden türetilmiştir.

[6]'da sEMG sinyalinin karakterizasyonunu ölçmek için bulanık entropi uygulanır sEMG sinyalinin gizli dinamik karakteristiklerini değerlendirmek için [7]'de tekrar eden plotlara (*recurrence plot*) dayalı lineer olmayan ölçümlemeden yararlanılır.

[6,8]'da patolojik titreme sırasında oluşan sEMG sinyalinin benzetimi için yeni bir çok ölçekli model ile yinelemeli Hilbert transform kullanıldı. [9]'da el hareketinin EMG sinyal işleme, lineer multiple regression modeli ile temsil edilir. sEMG sinyalinin gelişmiş sinyal işleme kaçınılmaz biçimde, "zihin-kontrollü yapay eller" olarak adlandırılan gelişmiş çok işlevli üst kol protezlerinin geliştirilmesini sağlayacaktır[10].

[11]'de EMG örüntü tanımlaması için autoregressive modeller ve bir sinir ağı kullanıldı. Sanal protezdeki hareketlerin kontrolündeki başarı oranları %100'dür.

[12]'de el hareketi komutlarını tanımlamak için uyarlanabilir neuro-fuzzy çıkarım sistemi önerilmiştir ve eğitim için hybrid bir algoritma kullanıldı. Ortalama sınıflandırma oranı %92'dir.

[13]'de 20 denek bilek hareketleri yaparken izometrik kasılma ve karşı kasılma EMG sinyalleri yüzey elektrotlarla kaydedilmiş ve bu datalar sınıflandırılmıştır.

[14] 'te el protezinin hareketlerinin modelini tanımlamak için yüzeysel EMG sinyallerinden yararlanılmıştır. Protez bir elin kontrolü için de hareket komutlarını belirlemeyi amaçlayan bir bulanık mantık çıkarım sistemi önerilmiştir. Sınıflandırmada yararlanan miyoelektrik sinyaller, altı (el hareketinden oluşmaktadır. Bu çalışmada tasarlanan ve kullanılan bulanık mantık sistemleri, bağımsız olarak ve hem zaman hem de zaman-frekans özellikleri için karma bir biçimde test edilmiştir. Bu birleşik yaklaşım için sistemin ortalama hassasiyetinin %96 olduğu bildirilmiştir.

[15]'te miyoelektrik protezleri kontrol amacı ile çok kanallı EMG işaretlerinin danışmanlı sınıflandırılması için bir yöntem önermektedir. EMG işaretinin Ayırık Dalgacık

dönüşümünün

üzerine temellendirilmiştir. Çok kanallı çözüm kümesinde SVM yaklaşımıyla sınıflandırma gerçekleşir. Kolun üzerindeki 8 bölgeden kaydedilen EMG ile 6 el hareketinin sınıflandırılmasında bu metot uygulanmıştır.

[16]'da örüntü tanıma temelli ve örüntü tanıma temelli olmayan miyoelektrik kontrol üzerinde son zamanlarda yapılan araştırma ve geliştirmeleri gözden geçirerek tiplerine, yapılarına ve mevcut uygulamalara bağlı en son başarıları sunmaktadır.

[17] 'de miyoelektrik işaretler kullanarak üst bacak hareketlerine DVM uygulanmasını önermiş ve değerlendirmişlerdir. Myoelektrik kontrolün sınıflandırılmasında temel olan DVM, çok katmanlı perseptron sinir ağları ve lineer diskriminant analiz karşılaştırılmıştır. Bu karşılaştırma DVM'nin olağan üstü doğruluğunu, güçlü performansını ve düşük hesaplama yükünü göstermiştir.

[18]'de sEMG sinyalinin modellenmesinde EM (expectation maximization) algoritması ile beraber AR,ARMA,ARIMA,WAMP, RMS, MUAP ve GMM modellerinin farklı ikili kombinasyonlarının veri kümesini temsil yetenekleri kıyaslanmıştır. Sınıflandırma algoritması olarak back propagation (BP) ve support vector machine (SVM) incelenmiş ve ortalama % 93 sınıflandırma başarımları elde edilmiştir.


Özgün Değer: Bu çalışma kapsamında lineer ve durağan olmayan EMG işaretine Ayrık Dalgacık Dönüşümü uygulanarak ayrık hale getirilmiştir. Sinyallerin karakteristik temsil vektörü dalgacık katsayıları ve Markov geçiş matrisi elemanları ile belirlenmiştir. ADD işleminde yapılan testler sonucunda EMG sinyallerinin karakteristiğini en iyi yansıttığı görülen Daubechies dalgacık ailesi kullanılmıştır. Analiz sonrasında ayrık hale gelerek bağımsız değişken özelliği kazanan sinyal örnekleri üzerinde Markov modeli uygulanarak stokastik modellemesi yapılarak geçiş matrisi elde edilmiştir. Kullanılan iki basamaklı model ile tüm örnek veri setindeki sinyallerin öznitelik vektörleri elde edilmiştir. Veri setinin tamamı öznitelik vektörleri ile temsil edildikten sonra sinyali sınıflandırma aşamasına geçilmiştir. Çeşitli makine öğrenmesi algoritmaları ile sınıflandırılan veri seti için hangi algoritmanın daha başarılı olduğu yapılan testlerle incelenmiş ve uzaklık tabanlı algoritmaların söz konusu örneklem için daha verimli olduğu görülmüştür. uzaklık tabanlı algoritmalar sisteme nispeten daha az işlem ve bellek yükü getireceği için gerçek zamanlı çalışan sistemlerde tercih edilebilirliği yüksektir.

2. GENEL BİLGİLER

2.1. Kas Sistemi

2.1.1. Kasların Yapısı

İnsan organizması oldukça kompleks bir yapıya sahiptir. Hareketin oluşumunda iskelet sistemi ve eklemler kadar kas sistemi de önemli bir rol oynar. Kas sistemi insan vücut ağırlığının %40-50 sini oluşturur. İnsan vücudunda hareket etmeyi ve dik durmayı sağlayan 600'den fazla iskelet kası vardır. Kaslar vücudumuzun hareket etmesini sağlayan parçalarıdır. Kaslar olmadan, vücut hareketlerimiz kukla hareketine benzer olacaktır. Kemikler gibi, kaslar da vücudun hayati organları korur. Kaslar yapılarına ve konumuna göre sınıflandırılır[19]. Kasların karakteristik özelliği kimyasal enerjiyi (ATP) mekanik enerjiye dönüştürebilme yeteneğidir.



Şekil 2.1: İskelet kasının yapısı.


2.1.2 Kasların İşlevleri

Kaslar hemostatik dengeyi korumaya yönelik üç önemli işlevi gerçekleştirir. Bunlar hareket, destek ve ısı üretimidir.

Hareket: Kaslar temel fiziksel ve sosyal ihtiyaçların karşılanması gibi olumlu durumları gerçekleştirmek ve yangın, düşme, uygun olmayan ortam koşulları gibi olumsuz durumlardan kaçınmak için hareket üretir[20].

Destek: Hareket gerçekleşirken ya da vücut denge halindeyken uygun pozisyonun korunması/ devam ettirilmesi için kasılan kaslar dolaşım, solunum ve iskelet sistemine destek olur. Örneğin dik duruş kas kasılmalarıyla gerçekleştirilir [20].

Isı üretimi: Birçok insan normal vücut sıcaklığından daha soğuk çevrelerde bulunmakta ve vücutları ısı kaybetmektedir. Bu nedenle vücut ısısının korunması ve kısmen sabit olması; kalp atışı, solunumu sürdürmek, beyin faaliyetlerinin işlerliği gibi hayati faaliyetlerin devamı açısından büyük önem taşımaktadır. Vücutta ısı birçok farklı kimyasal reaksiyon sonucu oluşur. En çok ısı üreten sistemlerden biri kas sistemidir. Bunun nedenlerinden bazıları vücutta kapladığı alanın fazla olması ve vücut hareket halinde değilken bile gerçekleştirdiği reaksiyonların ısı üretimini arttırmasıdır. Yoğun egzersiz sırasında bu ısı üretimi daha fazladır [20].




Şekil 2.2: Farklı kas türlerinin mikroskobik görüntüleri.

2.1.3 Kas türleri

Kaslar temel olarak 3 sınıfta incelenebilir. Bunlardan ilki iskelet kasları olarak bilinen uzun ve silindirik şekilde çok çekirdekli hücrelerden oluşan çizgili kaslardır. Beyin kontrolünde istemli olarak çalışırlar ve vücut hareketlerinin önemli bir kısmını oluştururlar. İkincisi düz kaslardır ve otonom sinir sistemi kontrolünde istemsiz hareket ederler. Mide, bağırsak gibi iç organlarımızda bulunurlar. Üçüncüsü ise kardiyak kasıdır. Kardiyak kasının ayrı bir sınıfta değerlendirilmesinin nedeni çizgili kas olmasına rağmen istemsiz çalışmasıdır. Çizgili kaslar çizgisiz kaslardan daha hızlı çalışır. Tüm kas aktivitesi sinir sistemi tarafından etkilenir ve birlikte çalışırlar. Kaslar kasılma ve gevşeme hareketlerinin bir birini takibi sayesinde işlevlerini sürdürürler. Kaslar çekmek için takım halinde çalışır fakat itemezler. Bunun yerine kaslardan birisi çekme işini yaparken diğer kas ise işi yapmak için gevşemeye hazırlanır [19].

2.1.4 Aksiyon Potansiyeli

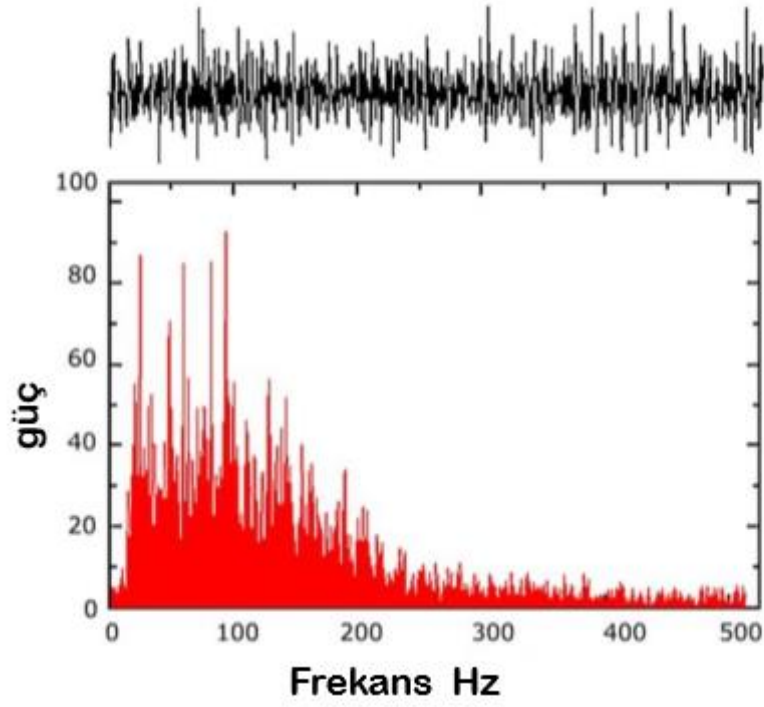
Fizyolojik olarak aksiyon potansiyeli bir hücrenin elektriksel potansiyelindeki anlık artış ve azalışları ifade eder. Bu olay birçok farklı canlı organizmada ya da aynı organizmanın çeşitli hücrelerinde değişik biçimde gerçekleşir. Aksiyon potansiyeli nöronlar arasında iletişimi, diğer hücrelerde ise hücre içi aktivitelerde görev almaktadır. Örneğin kas hücrelerinde aksiyon potansiyeli kasın kasılmasında ilk adımda görev alırken pankreasın beta hücrelerinde insülin salgılanmasını tetikler[21]. Aksiyon potansiyeli hücre zarında bulunan özel voltaj kanallarındaki iyon değişimiyle meydana gelir. Hücrenin zar potansiyeli dinlenme potansiyeline yakın olduğunda iyon kanalları kapalıdır. Kanalların hızla açılması kesin olarak hücrede eşik değerinin üstünde bir potansiyel farkı oluştuğunu gösterir. Aksiyon potansiyeli hücre zarındaki sodyum ve potasyum iyonlarının yarattığı polarizasyon değişimiyle oluşur. Potansiyel farkı belli bir eşik değerinin üzerine çıktığında Na^{+} ve K^{+} iyonları nörondan gelen sinyale yanıt olarak hareketlenir. Aksiyon potansiyeli oluşurken başlangıçta Na^{+} kanalları açılır ve Na^{+} iyonları harekete geçer. Bu durum depolarizasyona neden olur. K^{+} kanallarının açılması ve K^{+} iyonlarının harekete geçmesi ise repolarizasyon oluşturur. Hücre içi ve dışında oluşan bu polarite nöron sinyalleri ile akson terminali arasında haberleşme sağlar.



Şekil 2.3: Aksiyon potansiyeli oluşumu.

2.2. Elektromiyografi

Elektromiyografi (EMG), iskelet kasları tarafından gerçekleştirilen elektriksel faaliyetlerin değerlendirilmesini ve kayıt altına alınmasını sağlayan tıbbi bir elektrodyagnostik araçtır [22]. Kasların kasılması ve gevşemesi sırasında ortaya çıkan potansiyel değişim elektromiyogram cihazına bağlı elektrotlarla ölçülür. Bu alanda yapılan ilk çalışmalar daha önceki tarihleri işaret etse de mikrovolt aralığındaki sinyalleri iletebilecek kablolar 1980lerde üretilmeye ve kullanılmaya başlanmıştır. Sonraki süreçlerde de daha hassas ve verimli ölçüm yapan enstrümanlar geliştirilmeye devam edilmiştir. Tipik bir EMG işareti Şekil 2.4 'teki gibidir. EMG işaretleri ölçülürken güç ve frekans değerleri kaydedilir. EMG sinyalinin karakteristik özelliklerinden söz etmek gerekirse genlik aralığı 0-10mV veya 0-1,5mV (RMS) değerleri arasında değişkenlik gösterir. Sinyal enerjisi 50 ile 500Hz frekans aralığında olmakla birlikte sıklıkla 50-150Hz aralığında değerler alır[23].




Şekil 2.4: Örnek EMG Sinyali Güç ve Frekans Grafiği.

EMG'nin birçok farklı uygulaması mevcuttur. EMG sinyalleri tıp bilimlerinde kas ve sinir hastalıklarının teşhis ve tedavisinde kullanılmasının yanında, kesik uzuvların yerine eklenmesinde ve biyomühendislik çalışmalarında protez uzuvların geliştirilmesinde sıklıkla kaynak işareti olarak kullanılmaktadır. Bu sinyaller düşük genliğe sahip oldukları için gürültülerden çok çabuk etkilenebilmektedir. EMG sinyalinin dinamik karakteristiklerin kesinliğini geliştirmek için sinyalin matematiksel modelini oluşturmaya yönelik ilgi son yıllarda da devam etmektedir. EMG işaretleri stokastik özellik gösterir. Bu yüzden analizlerde farklı yöntemler kullanılır. EMG sinyalinin dinamik karakteristiklerin kesinliğini geliştirmek için sinyalin matematiksel modelini oluşturmaya yönelik ilgi son yıllarda da devam etmektedir.

2.2.1. Elektromiyografi Çeşitleri

Elektrotlar vasıtasıyla hareket halindeki (kasılma, gevşeme) kasın elektriksel aktivitesi sonucu değişen potansiyel değerleri kaydedilir. Bunlar EMG işaretini oluşturur. Genel anlamda iki tür EMG türü vardır. Bunlar, yüzey EMG ve kasiçi EMG'dir. Yüzey EMG, yüzey elektrotları; kasiçi EMG ise iğne elektrotları yardımı ile ölçülür. Bunların dışında, uyarılabilen hücrelerin elektriksel davranışlarını inceleyebilmek için mikroelektrotlar ve hücre uyarmada kullanılan elektrotlar bulunmaktadır.


Yüzey elektrotlarının Şekil 31'de görülebileceği gibi farklı çeşitleri olmasına rağmen EMG ölçümleri için en sık kullanılanı Metal plaka elektrotu olanıdır. Metal Plaka elektrotlar; EMG, EEG ve EKG işaretlerine duyarlıdır ve bunları algılayıp kaydetme işleminde kullanılır. Deri üzerine yerleştirilen metal yüzeye sahiptir. Araya elektrolit özellikle bir pasta uygulanır. Bu tip elektrotlarda metal olarak genellikle Ni-Ag (nikel-gümüş) alaşımı kullanılır. Bu elektrotların temas yüzeyleri geniş olduğu için empedansları küçüktür (2-10 Kohm) [24,25].



Şekil 2.5: Yüzey elektrot çeşitleri [24].


İğne elektrotlar, kaslara batırılmak suretiyle uygulanır. Diğer bir deyişle, işaretleri vücudun yüzeyinden değil, bizzat kasın içinden alırlar. Dâhili elektrotlar ile kararlı

işaretler alınabilmesine karşın, kullanımı hastayı rahatsız ettiğinden yüzey elektrotlarının yetersiz kaldığı durumlarda kullanılırlar [24,26]. Şekil 2.6'da görülebileceği gibi birçok iğne elektrot çeşidi mevcuttur.



Şekil 2.6: İğne elektrot çeşitleri [24].

Elektrot seçimi kullanım yerine ve amacına göre farklı şekillerde tercih edilebilir. Buna karşın yüzey elektrotlar ile iğne elektrotlar karşılaştırıldığında Şekil 2.7'de görülebileceği gibi iğne elektrotların daha kararlı ve hassas sonuç verdiği bilinmektedir.



Şekil 2.7: Yüzey ve İğne Elektrot ile Yapılan Ölçümlerin Karşılaştırılması[24].

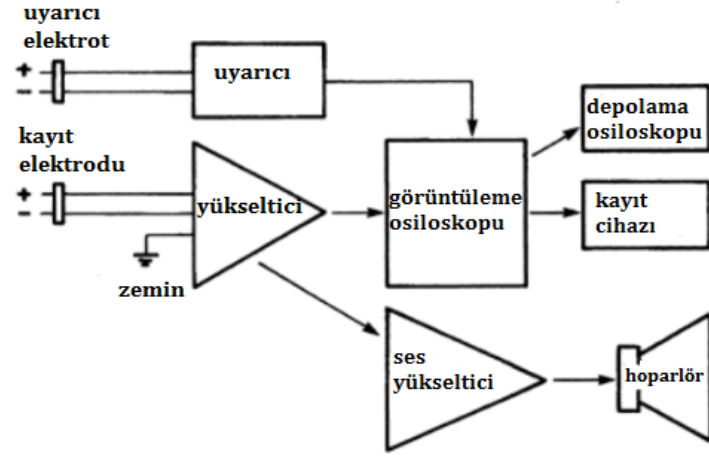
2.2.2. Elektromyogramın Teknik Kısımları

EMG sistemi 0,5 μ V - 10mV arasındaki voltaj değerlerine ve 1-30 000 Hz arasındaki frekans değerlerine cevap verebilecek şekilde tasarlanmış olmalıdır. Şekil 2.8'de gösterildiği gibi standart bir EMG cihazı aşağıdaki bileşenleri barındırmalıdır [27].

Yükseltici: Kayıt elektrotları tarafından toplanan potansiyel değerler genelde çok küçük şiddette oldukları için görüntülenmeden ve kayıt edilmeden önce bir yükseltici tarafından yükseltilmesi gerekmektedir. Yükselticinin bir diğer görevi gereksiz bozucu sinyallerin girişini engellemektir. Yükselticiler duyarlılık ve frekans filtre seçimi için iki farklı kontrol sistemine sahiptirler. Birçok EMG sistemleri 5 ile 10 000 μ V (10 mV) aralığında duyarlılığa sahiptir. Duyarlı bir yükselticide bu seviye 0,5 μ V değerine kadar yükselmektedir. Yükselticilerde alçak geçiren filtre ve yüksek geçiren filtre çeşitleri mevcuttur. Sonuç olarak, yükselticilerde filtre seçiminde EMG potansiyellerinin frekans karakteristiklerinin dikkate alınması çok önemlidir [27].

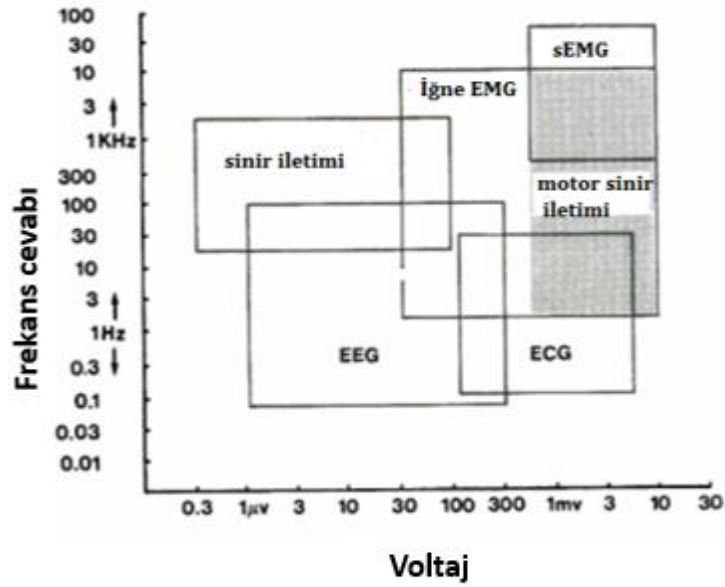
Osiloskop: Lineer bir zaman süreci boyunca potansiyel değerini anlık gösterebilen cihazlardır. Birçok durumda EMG osiloskopta algılanan frekansı tanımlar ve klinik önem bakımından yorumlar. Kayıt osiloskopu ise verinin silme tuşuna basılmadan silinmesini engelleyen özel bir osiloskoptur. *İşitsel Yükseltgeç ve Hoparlör:* Osiloskopta görüntülenen potansiyel değerlere ek olarak karakteristik sesler üreten ve bu seslerin ortama verilmesini sağlayan sistemdir. *Uyarıcı (Stimülatör):* Sinirlerin uyarılması amacı ile kısa bir süreliğine kare dalga elektrik akımı üreten sistemlerdir. Uyarıcı sistemlerde uyarım süresinin ayarlanması, uyarım yoğunluğunun ayarlanması ve uyarım oranının ayarlanması şeklinde üç farklı kontrol yöntemi vardır [27].

EMG sinyallerini işlemek için basit anlamda bir yükselteci, alçak-yüksek geçiren filtrelere ve sinyal doğrultucuya ihtiyaç vardır. Kazanılan sinyal fark yükselteci ile yükseltilerek filtreden geçirilir. Sonrasında gürültü azaltma işlemi yapılır.



Şekil 2.8: Standart Bir EMG Sisteminin Bileşenleri.

Şekil 2.9'da gösterildiği gibi frekans ve voltaj değerleri dikkate alındığında, EMG sisteminin EKG ve EEG sistemlerine göre çok daha karmaşık bir yapıda olduğu görülebilmektedir.

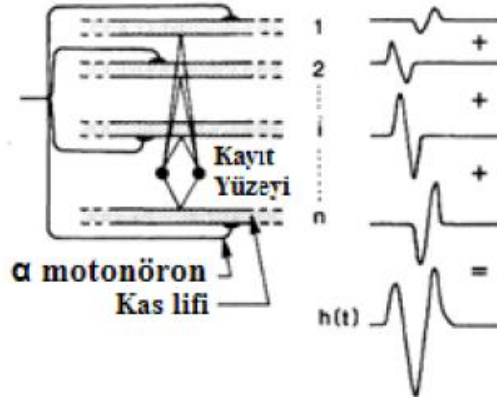


Şekil 2.9: EMG, EEG ve EKG sistemlerinin frekans ve voltaj aralıklarındaki çalışma durumları.

2.2.3. Motor Birim ve Motor Ünite Aksiyon Potansiyeli (MÜAP)


Motor birim motor nöron, aksonlar ve iskelet kaslarından oluşur. Kas sistemindeki en küçük fonksiyonel birimdir. Bir araya gelerek Motor ünitelerini oluştururlar ve her motor birim belli bir kası kontrol ederek hareketi sağlamak için çalışırlar. Boyutları ve kapasiteleri farklıdır. Kaslarda uyarılma oranı motor nöron başına 100-150 kas lifi olurken bazı kaslarda bu oran fazlaca artıp azalabilmektedir[28].

İskelet kaslarında yapılacak olan işin büyüklüğü aktive edilecek motor birim sayısını belirler. Ne kadar fazla güç harcanırsa aktive edilen motor birim sayısı artar. Bir motor birim uyarıldığı zaman iyonların geçişi nedeniyle liflerde meydana gelen aksiyon potansiyelleri birbirinin üstüne binerek Şekil 2.10'da görüneceği gibi motor birim aksiyon potansiyelini (MUAP) oluştururlar[28,29, 30].



Şekil 2.10: Motor birim aksiyon potansiyeli[28].

Bir kasın kasılmayı sürdürmesi için motor birimler art arda çalışmalıdır. Başka bir deyişle kasılma anında MUAP'lar duruma göre değişken aralıklarla tekrar edilmelidir. Bu işlemle oluşan ardışık dizilere MUAP dizileri (MUAPT) adı verilir (Şekil 2.11). Bu ardışıklık motor birim ateşleme paternleriyle (FP) sağlanır. Ham EMG işareti incelenmek istenen kasın üzerine yerleştirilen elektrotun ölçtüğü MUAPT'ların süperpozisyonu sonucu oluşan elektriksel işarettir[28].



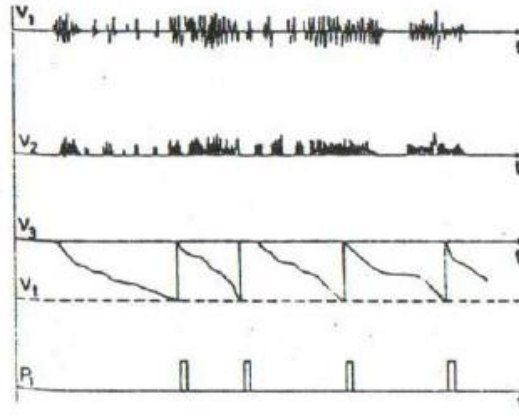
Şekil 2.11: MUAP dizileri [28,34].

EMG işareti için kabul edilen temel matematiksel model kasılma anındaki MUAP'ların toplamı olarak 2.1'de gösterildiği gibidir. Eşitlikte $m(t)$ modellenmiş EMG işaretini, $a(t)$ ateşleme paternini, $h(k)$ MUAP 'ı, $w(t)$ sıfır ortalamalı beyaz Gauss gürültüsünü ve B 'de motor birim ateşleme sayısını gösterir[31,32].

$$m(t) = \sum_{k=0}^{B-1} h(k)a(t - k) + w(t) \quad (2.1)$$


2.3. EMG İşaretleri Analizi (Modelleme , zaman, frekans domeni,gürültü)

Bir EMG işaretini zaman domeninde incelemek için; öncelikle doğrultma işlemi yapılır. Bu işlem için enerji kaybını önlemek adına tam dalga doğrultma işlemi tercih edilerek orjinal işaretin mutlak değeri üzerinden işlem yapılabilir. Doğrultulmuş sinyal üzerindeki rastgele değişimlerin ve gürültüler bir alçak geçiren filtreden geçirilerek giderilir. İşaretteki rastgele büyük değişimleri yok etmek içinse ortalama alma işlemleri uygulanabilir. İntegral alma işlemi alçak frekansları filtrelemenin özel bir türü olmasının yanında EMG işaretlerinde veri azaltmak için en sık kullanılan yöntemlerdendir [24,26].



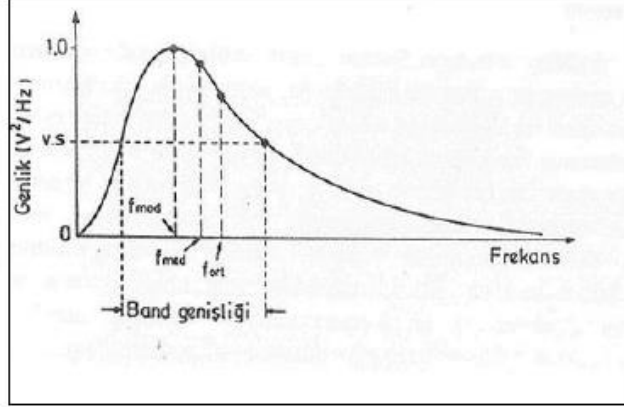
Şekil 2.12: İntegratörün çeşitli noktalarındaki işaretlerin zamana göre değişimi [31].

Yukarıda belirtilen işlemlerin yanında etkin değerin ölçülmesi gibi özel hesaplamalar da yapılabilir. Bu işlemlerde kare dalga, sinus dalgası gibi düzenli bir işareti olan sinyallerin genlikleri kullanılarak etkin değerlerinin hesaplanması söz konusudur. Fakat EMG işaretleri rastgele değişen değerlerden oluştuğu için etkin değer hesaplanması anlam taşımaz. Sıfır geçişlerin sayılması da işaret hakkında bilgi verir. Bu işlemde işaretin sıfır noktasından geçiş sayısı bulunur. Düşük enerjili kas kasılmalarında pozitif ve negatif değerler arasındaki değişim sayısı ile Motor Ünitesi Aksiyon potansiyeli arasında lineer bir korelasyon bulunur [24, 26].



Şekil 2.13: EMG işaretlerinin elektrota ulaşıncaya kadar geçtiği işlemler [24].

Bir EMG işaretini frekans domeninde incelemek için; bu işaretlerin frekans spektrumundaki median frekansı, ortalama frekans, spektrum band genişliği gibi parametrelerinin hesaplanması gerekir. Güç spectrum analizinin yapılması için genellikle Hızlı Fourier Dönüşümleri kullanılmaktadır. Şekil 2.14’de bir EMG işaretini parametreleriyle birlikte gösterilmiştir[33].



Şekil 2.14: İdealize edilmiş EMG işareti güç spectrum yoğunluğu [24].



3. BİYOMEDİKAL İŞARET İŞLEME

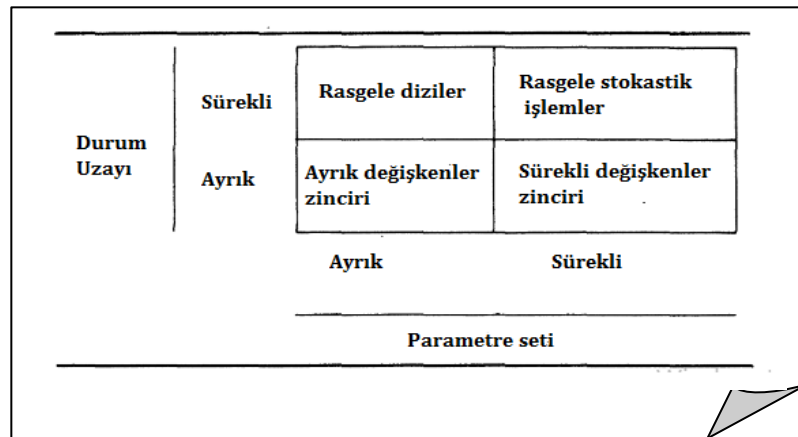
3.1. Rasgele İşaretlerin İşlenmesi

3.1.1. Stokastik süreç ve Markov modeli

Markov modeli


X rastgele değişkeninin belirli bir zaman uzayındaki değerlerinin belirli bir süreç içindeki değerlerinin dizilimiyle oluşan sürece stokastik süreç denir. Yule (1927) tarafından öne sürülen bir hipotezle başlamıştır. Stokastik süreçler gözlenen değerlerle yüksek derecede ilişkili olan serilerinin olasılık yasalarına uygun olarak zaman uzayında gerçekleşen değişimleriyle ilgilenir. Stokastik süreçler teorisi bilim ve teknolojinin birçok dalındaki geniş olaylar dizisi için uygulanabilir.

Stokastik süreç $\{x_t, t \in T\}$ rastgele değişkenlerden oluşur. Burada stokastik ve rastgele eş anlamlı olarak kullanılmaktadır. t parametresi zamanı ifade etmektedir. Eğer rastgele değişkenler vektörü ayrık ise stokastik süreçte ayrıca bir durum alanı mevcut olur. T parametre seti ayrık olabileceği gibi sürekli de olabilir. Eğer ayrık ise ($T=\{1,2,\dots,N\}$, $T=\{1,2,\dots\}$) stokastik süreç bir ayrık parametre sürecidir; sürekli ise ($T=[0,1]$, $T=\{t:t \geq 0\}$). sürekli parametre sürecidir. Bu sınıflandırma ile ilgili bir diyagram çizelge 3.1 de verilmiştir[41].



Çizelge 3.1 : Stokastik süreçlerde sınıflandırma.

Aşağıda basit bir rastgele süreç örneği (Random Walk) görülmektedir.



Şekil 3.1: Örnek bir rastgele süreç gösterimi.

Başka bir stokastik süreç örneği vermek gerekirse; Dünya etrafında periyodik bir yörüngedeki bir uyduyu ele alalım. Uydu üzerine etki eden kuvvetlerin tamamı bilinemez. Bu durumda uydunun hareketi rastgele stokastik bir diferansiyel denklemle ifade edilebilir. Bu denklemin çözümünün bir parçası olan h_1 (uydunun yüksekliği), π 'nin orbital periyot olduğu sürekli durum değişkenli ve sürekli parametrelili stokastik bir süreçtir $\{h_1, t \in [0, \pi]\}$. Aşağıdaki grafikte gerçekleşen sürecin k ve $k+1$ durumlarındaki değişimleri görülmektedir[41].




FIG. 3.2. Satellite altitude.

Şekil 3.2: Örnek bir rastgele süreç gösterimi-2.

3.1.1.1. Fourier dönüşümü

Sürekli periyodik bir sinyal sinüs ve kosinüs fonksiyonlarının toplam bileşenlerinden oluşur. Bu matematiksel olarak kompleks ve üstel fonksiyonların toplamı olarak ifade edilir. Fourier serileri ise sinüs ve kosinüs fonksiyonlarının ortogonal ilişkilerinden yararlanılarak sinyal işlemede bir yöntem olarak kullanılmaktadır [5,7]. Fourier dönüşümü ile durağan sinyallerin analizinde başarı elde edilirken, durağan olmayan sinyaller için aynı başarılı analiz söz konusu değildir. Bunun nedeni ise Fourier dönüşümü sırasında bir sinyali zaman bölgesinden frekans bölgesine dönüştürürken sinyalin zaman bilgisinin kaybolmasıdır. Durağan olmayan sinyallerin özel bölgelerinde gerçekleşen değişimlerin nerede olduğuna dair zaman bilgisi verisi olmadığı için Fourier analiz verimliliği bu tür sinyallerde düşmektedir. Zaman-frekans dönüşümleri aşağıdaki denklemlerle ifade edildiği gibidir[34,35,36].

$$\begin{aligned} f(t) &= \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) e^{-j\omega t} d\omega \\ F(\omega) &= \int_{-\infty}^{\infty} f(t) e^{j\omega t} dt \end{aligned} \quad (3.1)$$

Başka bir ifadeyle yine Fourier dönüşümü ile trigonometrik bir seri cinsinden açılarak temsil edilen bir sinyal hakkında çok şey söyleyebiliriz. Bir sinyalin trigonometrik seriye açılımı aşağıdaki gibi ifade edilebilir. $f(x)$, x değişkenine bağlı $2a$ periyotlu periyodik bir fonksiyon, $a_n, b_n, n=1,2,3 \dots$ gibi sabit katsayılar olmak üzere denklem (2.22)'deki gibi ifade edilir[37]:

$$f(x) = a_0 + \sum_{n=1}^{\infty} \left[a_n \cos\left(\frac{n\pi x}{a}\right) + b_n \sin\left(\frac{n\pi x}{a}\right) \right] \quad (3.2.22)$$

Kısacası fourier dönüşümü, farklı frekanslar içeren periyodik bir sinyalin, sinüs ve kosinüs harmonik fonksiyonları türünden gösterimini sağlar. Bu yöntem bulunduğu zaman analiz ve temsil yeteneği açısından güçlü olduğu için oldukça ses getirmiştir.

Bu dönüşüm;

- Yüksek frekanslı gürültünün yok edilmesini sağlar,
- Verinin sıkıştırılabilmesini sağlar,
- Sinyalin fiziksel özellikleri ile ilgili detaylı veri sunar,
- Bir problem söz konusu olursa, incelenmesi gereken bölümleri sınıflandırarak sorunun kaynağının daha kolay bulunmasını sağlar[37].

3.1.1.2. Kısa süreli fourier dönüşümü


Fourier analizi, durağan olmayan sinyallerin frekanslarının zamansal değişimini analiz konusunda yetersiz olunca Kısa Süreli Fourier Dönüşümü ile bu sorun kısmen çözülmeye çalışıldı. Bu dönüşüm ile söz konusu sinyalin küçük bir parçası zaman tanım aralığında pencereleme yöntemi adı verilen bir yöntem uygulanarak analiz edilerek hangi frekansların hangi zaman diliminde gerçekleştiği hakkında bilgi edinildi. Bu yöntemde sinyalin zaman bölgesindeki fonksiyonu pencere fonksiyonu ile çarpılarak sinyal birbirine bitişik kesitlere ayrılır. Ardından her kesite Fourier Dönüşüm tekniği uygulanır ve bu yüzden yöntem Kısa Süreli Fourier Dönüşümü olarak bilinir[34,35,36]. Sabit aralıklar ile adım adım yapılan bu işlem, sinyalin zamana bağlı frekans ve faz değişimlerini ortaya koymaktadır[37].

$x(t)$, t üzerinde tanımlı bir fonksiyon , τ öteleme miktarı ve w pencere fonksiyonu olmak üzere KSFD'nin matematiksel ifadesi aşağıdaki denklemdeki gibidir. (3.3)

$$KSFD\{x(t)\}(\tau, \omega) = \int_{-\infty}^{\infty} x(t)\omega(t - \tau)e^{-j\omega t} dt$$


Burada söz konusu pencere fonksiyonunu τ aralıkla t üzerinde kaydırılarak her seferinde pencere içindeki bölüme Fourier dönüşümü uygulanır. Bu pencereler bandpass- den pratikte en çok kullanılanları Hamming, Hanning, Bessel, Butterworth ve Chebyshev sayılabilir. KSFD'nin pratikte kullanıldığı ayrık formu, n ayrık sinyaldeki değerlerin sayacı olmak üzere, (2.51) denklemindeki şekliyle ifade edilir[37].

$$KSFD\{x[n]\}(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]\omega[n - m]e^{-j\omega n} \quad (3.4)$$



Şekil 3.3: Durağan bir sinüs fonksiyonunun Hanning pencere fonksiyonu uygulanmadan önceki ve sonraki görünümü[37].

KSFD’de pencere genişliği tüm analiz boyunca sabit olduğu için, belirsizlik ilkesi ile verilen belirsizlik kutucukları fonksiyonun söz konusu pencere ile ne kadar iyi ifade edilebildiğini, yani çözünürlüğü belirler. Aşağıdaki Şekil 3.4’den görüleceği üzere, Fourier dönüşümünde zaman çözünürlüğü sıfırdır. Başka bir deyişle, dönüşüm sonucunda bulunan frekansların, sinyalin her anında var olduğu kabul edilir[37].



Şekil 3.4: Fourier dönüşümü ve KSFD temsili çözünürlük farkları [44].


KSFD’de ise zamana bağlı çözünürlük mevcuttur ancak frekans çözünürlüğü gibi, o da sabittir. Bu fark sabit çözünürlük kutucuklarıyla gösterilebilir[37].

Dönüşüm	Gösterim	Giriş
FOURIER DÖNÜŞÜMÜ	$f(\xi) = \int_{-\infty}^{\infty} f(x)e^{-2\pi i x \xi} dx$	ξ , frekans
ZAMAN-FREKANS ANALİZİ	$X(t, f)$	t , zaman ; f , frekans
DALGACIK DÖNÜŞÜMÜ	$X(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \overline{\Psi\left(\frac{t-b}{a}\right)} x(t) dt$	a , ölçek ; b , zaman

Çizelge 3.2: Fourier dönüşümü ve Dalgacık dönüşümü gösterimler.

3.1.2. Dalgacık analizi ve dalgacık türleri

Bir sinyal için örnekleme frekansı arttıkça çözünürlükte artmakta, sinyalin temsil yeteneği güçlenmektedir. Fourier dönüşümü tek bir çözünürlükte çalışmaktadır. KSFD de benzer şekilde, sadece pencereler aracılığıyla sinyali daha küçük parçalara bölmesi dışında Fourier dönüşümü ile aynı prensiple yani tek çözünürlük boyutu ile çalışır. Ancak KSFD'nin çözünürlüğünü pencere genişliği belirler. Geniş destekli pencereler iyi frekans çözünürlüğü fakat düşük zaman çözünürlüğü sağlarken, dar destekli pencereler iyi zaman çözünürlüğü fakat düşük frekans çözünürlüğü sağlar. Bu nedenle, sinyalin durağan bölgelerinde çalıştığı gibi keskin değişimlerin olduğu bölgelerinde farklı çözünürlükten çalışabilecek bir analiz yöntemine ihtiyaç duyulmuştur ve çoklu çözünürlüklü dalgacık dönüşümü ortaya çıkmıştır[37].




Şekil 3.5: Çoklu çözünürlük gösterimi.

Dalgacık dönüşümü çoklu çözünürlük sayesinde sinyalleri daha iyi analiz edebilmeyi mümkün kılmakla birlikte sinyali gürültüden kurtarma yeteneği de fazladır. Bunun yanında sinyali küçük boyutlarda saklama imkanı da sağlamaktadır.


Dalgacık dönüşümü, farklı filtreler sayesinde sinyal analizi işlemine farklı boyutlar kazandırmıştır. Dönüşüm, temel sinyali bir çok yüksek geçişli (high-pass) ve alçak geçişli (low-pass) filtreden geçirerek, her bir filtreye ait katsayılar ile temsil eder. Bu işlem filtrelerin sayısına ve çözünürlüğüne bağlı olarak sinyalin karakteristiğini yansıtacak detaylandırmanın yapılmasını sağlar.

Dalgacık analizi sinyallerin analizinde sıklıkla kullanılan bir analiz metodudur. Sinyallerdeki boşluklar, eğimleri, kırılma noktaları vs. noktaları analiz ederek sinyal karakteristiği hakkında bilgi verir. Bunun yanında sinyali sadece analiz için değil sıkıştırma, gürültüden arındırma ve eski haline getirme işlemlerini sinyalin orijinalini bozmadan yapma yeteneği vardır[38].

Bu fonksiyonlar, örnekleme frekansı 2^j olan $f_j(x)$ sinyalinin en yüksek çözünürlük basamağından başlayıp bileşenlerine ayrılır. Her adımda sinyal iki ana bölüme ayrılır ve alçak geçişli filtre ile elde edilen kısım o adım için sinyalin ana hattını verirken, yine her adımda yüksek geçişli filtre ile sinyalin o adımdaki detayları yakalanır. Örnek şekil 3.6 ile görselleştirilmiştir[37].



Şekil 3.6: $f_j(x)$ sinyalinin yüksek geçişli ve alçak geçişli filtrelerden geçirilip farklı çözünürlük kademeleri için bir katsayı oluşturması.



Şekil 3.7: Bir sinyalin Haar dalgacı ile 3 kademe ayrıştırılması.

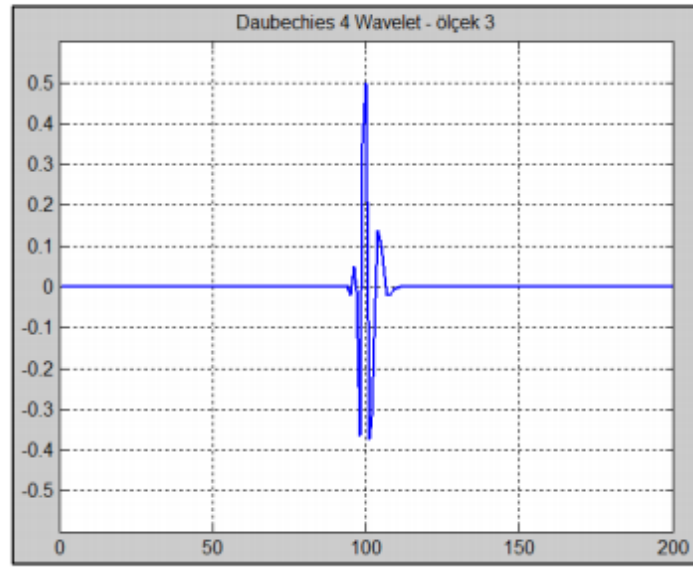
3.1.2.1. Sürekli dalgacık dönüşümü

Matematiksel olarak Fourier dönüşümüyle gösterilir. Dönüşüm, $f(t)$ gibi bir fonksiyon için, o fonksiyonun dalgacık fonksiyonu ile iç çarpımı olarak tanımlanır:


$$Wf(u, s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \overline{\psi\left(\frac{t-u}{s}\right)} dt \quad (3.5)$$

Buradaki s ölçek ve u konumu ifade etmektedir. Bu dönüşüm, dalgacık fonksiyonunun (ψ) kaydırılıp bir ölçekle çarpıldıktan sonra zaman alanı boyunca toplanmasıdır. Bu dönüşüm hesabı, dalgacık dönüşümü mantığının temelini olmasının yanında pratikte her zaman sisteme ek hesap yükü getirdiği için mümkün olduğu kadar ayrık dönüşüm tercih edilir. Sürekli dalgacık dönüşümü ise, sinyal içindeki süreksizliklerin belirlenmesinde ve ne kadarının gürültü ne kadarının sinyalin karakteristiğini yansıttığını belirlemede kullanılabilir. SDD'nin sonucunda ölçek ve konum fonksiyonu olan birçok dalgacık katsayıları C elde edilir[37,44].

SDD'nin çalışma prensibini incelediğimizde; bir dalgacık öncelikle sinyalin başlangıç bölümüyle karşılaştırılır, ardından dalgacık ile sinyal arasındaki korelasyon katsayısı olan C hesaplanır. C katsayısı ne kadar büyükse korelasyon yani ilişki o kadar fazla olacaktır. Sonrasında her döngüde dalgacık bir miktar sağa kaydırılarak aynı korelasyon hesabı parça parça tüm sinyal için yapılır. Farklı ölçeklerde içinde dalgacık yeniden ölçeklendirilip, korelasyon hesapları yine en baştan yapılır. Bu işlem ile sinyalin farklı bölgelerinde farklı ölçeklerdeki katsayıları elde edilir ve bu katsayılar sinyalin regresyon sonuçlarını verir[39].



Şekil 3.8: Daubechies 4 dalgacığının 3. ölçekteki görünümü.



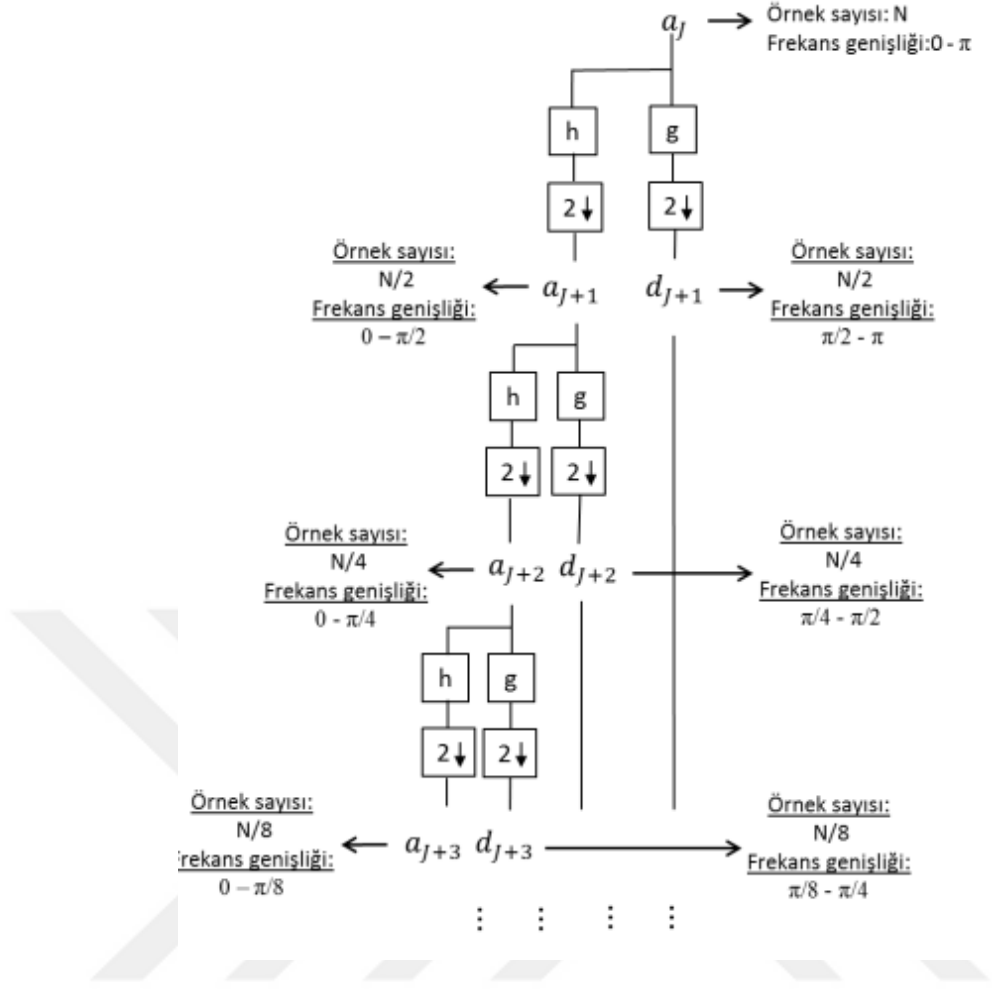
Şekil 3.9: Daubechies 4 dalgacığının 3. Ölçekte örnek sinyal üzerinde ötelenmesi.

Tüm sinyal sonra bir üst seviye ölçeğe geçilir. Bu her büyüyen ölçekle dalgacık fonksiyonu yeniden sinyali tarar. Her ölçek farklı frekanslardaki sinyallerin detaylarını farklı oranlarda yakalama yeteneğine sahiptir. Artan ölçek değerlerinin, sinyaldeki düşük frekanslı detayları, düşük ölçek değerlerinin ise yüksek frekanslı detayları temsil etme yeteneği yüksektir. Sürekli dalgacık analizinde kullanılan dalgacık türleri arasında Mexican Hat, Morlet, Gaussian, Meyer, Symmlets vb. vardır[37].

3.1.2.2. Ayrık dalgacık dönüşümü


Ayrık dalgacık dönüşümü (ADD), sürekli dalgacık dönüşümü ile aynı matematiksel temele dayanır, ancak yöntem farklılığı vardır. Sürekli dönüşümdeki dalgacık fonksiyonuna uygulanan ölçeklendirme-öteleme işlemi ADD'de dalgacığa alçak ve yüksek geçişli filtreler uygulanması ile yapılır. Bu durum sinyalin ayrık veri noktaları olarak, depolanıp işlenmesini sağlar yani dijital hale getirir. Dijital hale getirilen sinyal matrislerle ifade edilebilir, gürültüden daha kolay arındırılabilir ve sıkıştırma gibi işlemlerin yapılmasını kolaylaştırır. Eğer sürekli bir sinyal tüm ölçek aralığında analiz edilseydi analiz sonucu olarak çok büyük veri yığınları karşımıza çıkardı. Verimli bir analiz için ölçek grupları doğru tayin edilmelidir. Genellikle ölçek ve konum değerleri ikinin kuvveti olarak seçilir. Burada hesap yükü sınırı dizinin zaman alandaki genişliğiyle beraber ölçek ve konum değerlerinin tercihine bağlıdır. Yani mühendislikte sıklıkla kullanılan dalgacık dönüşümü genellikle Ayrık dalgacık dönüşümünü ifade eder. Ayrık dalgacık dönüşümü; sinyal işleme, görüntü işleme, sayısal analiz gibi birçok alanda kullanılır[37,39].

Genellikle ölçek ve konum değerleri ikinin kuvveti olarak seçildiği için ve her filtreleme adımı ile, örnek sayısı orjinaldekinin iki katına çıktığı için ($N+N=2N$), her filtre uygulamasından sonra Nyquist teoremindeki gibi örnek sayısının yarısı alınmaktadır. Böylelikle örnek sayısı sabit tutularak örneklem dengesi sağlanmaktadır. Örnek sayısını yarıya indirmek, ölçeği iki katına çıkarmaktır. Şekil 3.10'da bu ifade görselleştirilmiştir[37].

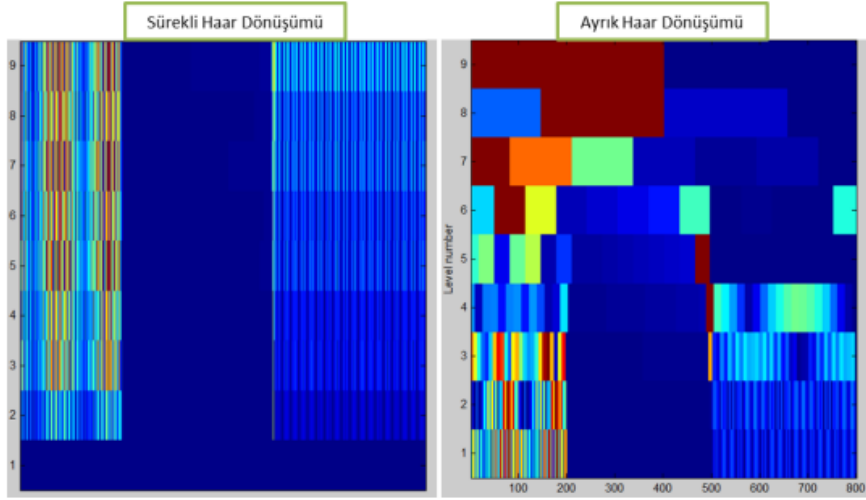


Şekil 3.10: Ayrıştırma işlemi.

Bu işlem sinyalin, dalgacık ve ölçek fonksiyonlarını içeren filtrelerle konvolüsyonu olarak algılanabilir. Sürekli dönüşümde, işlem yükü fazla olmasına karşın sinyalin karakteristik özelliklerini, ayrıntılarını, keskin değişimlerini ve süreksizlik özelliklerini daha iyi görebilirken, ayrık dönüşümde detay ve yaklaşık fonksiyonları, görüntü temizleme, gürültüden arındırma, ses kalitesi artırma gibi spesifik ve sinyal özgü işlemler daha verimli yapılabilir.



Şekil 3.11: Örnek sinyal.



Şekil 3.12: Örnek sinyalin sürekli ve ayrık dönüşümleri.


3.1.2.3. Temel dalgacık operatörleri

Dalgacıkların hepsi farklı karakteristikler taşır. Söz konusu farklar dalgacık türünün dahil olduğu aileye bağlı birleşme nokta sayıları, genişliği gibi küçük değişiklikler olabileceği gibi; ortogonal olup olmama, ölçek fonksiyonunun olup olmaması, kompleks olup olmaması gibi daha temel farklılıklar olabilir. Sık kullanılan dalgacık türlerine aşağıda değinilmiştir.



Şekil 3.13: Dalgacıkların genel sınıflandırılması.

Dalgacıklardaki en belirgin ayırım ‘‘Ayrık Dalgacıklar’’ ve ‘‘Sürekli Dalgacıklar’’ biçimindedir. Bazı dalgacıklar ise her iki dönüşüm içinde uygundur. Sürekli Dalgacıklar ; Haar, Daubechies, Symlets, Biorthogonal, Gauss, Mexican Hat, Coiflets, Meyer, Shannon, dalgacıklarıdır. Hem sürekli hem ayrık dönüşüme uygun olanları Haar, Daubechies, Symlets, Biorthogonal , Coiflets dalgacıklarıdır. Bunun yanında ayrık dalgacıklar Hermitian, Poisson, Spline, Stromberg dalgacıklarıdır. En çok bilinen kompleks dalgacıklar ise Complex Mexican Hat, Morlettir. En çok bilinen temel dalgacıklara ait temsiller şekil 3.14.teki gibidir.



Şekil 3.14: Farklı dalgacık ailelerine ait örnekler [43].

3.1.2.3.1 Haar dalgacı

İlk ortaya çıktığında dalgacık olarak tanımlanmayan "Haar Dalgacık" türü sınırlı durumlar ve uygulamalar için geçerli olup bilinen en basit ve eski dalgacık fonksiyonudur. Haar dönüşümlerinin temel fonksiyonları en eski ve en basit bilinen dikey (ortogonal) dalgacıklardır. Haar dönüşümlerini ayrılabilir ve simetriktir[18]. Haar dalgacığının ana fonksiyonu $\psi(t)$ olarak, ölçekleme fonksiyonu ise $\phi(t)$ olarak ifade edilirse;


$$\psi(t) = \begin{cases} 1 & 0 \leq t < \frac{1}{2}, \\ -1 & \frac{1}{2} \leq t < 1, \\ 0 & \text{diğerleri} \end{cases}, \quad \phi(t) = \begin{cases} 1 & 0 \leq t < 1, \\ 0 & \text{diğerleri} \end{cases}, \quad (3.6)$$

Matris olarak gösterimi; $T = HFH^T$ dir. F bir $N \times N$ matrisi, H $N \times N$ boyutlu bir dönüşüm matrisi ve T 'de yine $N \times N$ boyutlu bir dönüşüm matrisidir. Haar dönüşümü için, dönüşüm matrisi olan H , Haar'ın temel fonksiyonlarını içerir. Fonksiyonlar, $k=0,1,2,\dots,N-1$ ve $N=2^n$ için için $z \in [0,1]$ aralığı üzerinde belirtilir. H 'ı üretmek için k tamsayı tanımlanır ve $k = 2^p + q - 1$, $0 \leq p \leq n - 1$, $p=0$ için $q = 0$ veya 1 ve $p \neq 0$ için $1 \leq q \leq 2^p$ olmaktadır. Haar'ın temel fonksiyonları denklemler ve denklemlerdeki gibidir.

$$h_0(z) = h_{00}(z) = \frac{1}{\sqrt{N}}, \quad z \in [0,1] \quad (3.7)$$

$$h_k = h_{pq} = \frac{1}{\sqrt{N}} \begin{cases} 2^{p/2} & (q-1)/2^p \leq z < (q-0.5)/2^p \\ -2^{p/2} & (q-0.5)/2^p \leq z < q/2^p \\ 0 & \text{yoksa, } z \in [0,1] \end{cases} \quad (3.8)$$

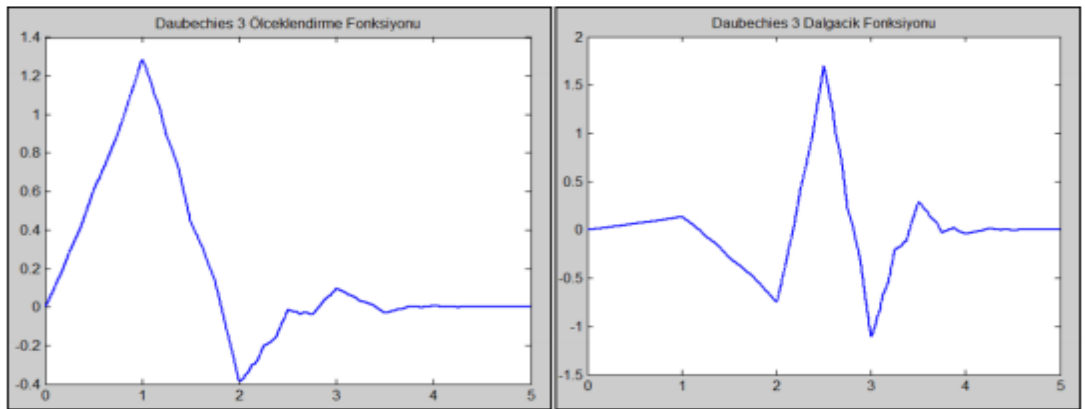
$N \times N$ Haar dönüştürme matrisindeki i . satır $z = 0/N, 1/N, 2/N, \dots, (N-1)/N$ için $h_i(z)$ 'nin elemanlarını içerir[46]. Haar dalgacığı en küçük desteğe sahip, en sade dalgacıktır. Yalnızca bir tek birleşme noktası olduğundan düzgün ve yumuşak geçişli fonksiyonlar için pek uygun bir sinyal temsili oluşturamaz. Ortogonal ve biortogonaldir, hem sürekli hem de ayrık dönüşüme uygundur. Haar dalgacığının ölçeklendirme ve dalgacık fonksiyonları şekil 2.32 ve 2.33'de verildiği gibidir[37].



Şekil 3.15: Haar ölçek ve dalgacık fonksiyonları.

3.1.2.3.2 Daubechies dalgacıkları


Daubechies dalgacıkları 1990'larda ortaya çıkmıştır. Oldukça sık kullanılan fraktal yapılar içeren bir dalgacık ailesidir. Daubechies dalgacıkları derecesine göre isimlendirilir, katsayıları ve tekrarlanma seviyesi ile ifade edilir. Örneğin Daubechies 3 dalgacı demek 3. derecedeki Daubechies dalgacı anlamına gelir. Dalgacıkların derecesi, birleşme noktalarının sayısıdır. Bu dalgacık ailesini ortogonal ve biortogonaldir. Ölçeklendirme fonksiyonuna uygundur ve hem sürekli hemde ADD'ye uygundur. N birleşme noktası sayısı için olabilecek en küçük $2N-1$ desteğe sahip dalgacık ailesidir. Süreklidir ve simetrik değildir. Bu dalgacıklar dereceleri yükseldikçe daha yumuşak hatlara dönüşmekte ve yumuşak geçişli sinyalleri daha iyi temsil yeteneği kazanmaktadır[37].



Şekil 3.16: Daubechies 3(a) Ölçeklendirme fonksiyonu, (b) Dalgacık fonksiyonu.

3.1.2.3.3 Symlet dalgacıkları

Symlet dalgacık ailesi, Daubechies dalgacıklarının hemen hemen simetrik halidir. Simetrik dalgacıklarla işlem bazı durumlarda önemsiz olurken, görüntü işleme, veri, sıkıştırma gibi bazı uygulamalarda önem kazanmaktadır. Bu eksikliği gidermek için daha simetrik ama yine küçük destekli bir dalgacık geliştirildi. Simetrik olmanın dezavantaj yarattığı olumsuzluk, sinyalin ayrıştırılması sonrasında mutlak şekilde yeniden geri çevirmenin her zaman mümkün olmayışıdır. Bu dalgacık ailesi ortogonal ve biortogonaldır. Ölçeklendirme fonksiyonu bulunur. Hem ayrık hemde sürekli dönüşüme uygundur. Simetriğe yakındır[37].




Şekil 3.17: Symlet 3(a) Ölçeklendirme fonksiyonu, (b) Dalgacık fonksiyonu.

3.1.2.3.4 Morlet dalgacı

Morlet dalgacı, Gabor dönüşümünün Grossman ile birlikte değiştirilerek kullanılması sonucu oluşmuştur. Bu dalgacık ortogonal değildir ve ölçeklendirme fonksiyonu bulunmaz. Morlet dalgacı fonksiyonu ve görüntüsü aşağıdaki gibidir[37].

$$\psi(x) = \frac{1}{\sqrt[4]{\pi}} \cos\left(x\pi \sqrt{\frac{2}{\log(2)}}\right) e^{\left(-\frac{x^2}{2}\right)} \quad (3.9)$$




Şekil 3.18: Morlet dalgacık fonksiyonu.

3.1.2.3.5 Mexican Hat dalgacıđı

Mexican Hat dalgacıđı, meksika şapkasına benzediđi için bu adla anılmaktadır. Bu dalgacık, Gauss dalgacık ailesinin ikinci dereceden dalgacıđıdır. Gösterim notasyonu ve sinyal gösterimi aşıđıdaki gibidir:

$$\psi(x) = \frac{2}{\sqrt{3}}\pi^{-\frac{1}{4}}(1 - t^2)e^{-\frac{x^2}{2}} \quad (3.10)$$



Şekil 3.19: Mexican Hat dalgacıđı.

Bu dalgacık ailesinin karakteristiklerinden söz etmek gerekirse; ortogonal veya biortogonal değildir ve ölçeklendirme fonksiyonu yoktur. Sadece sürekli dönüşüme uygundur ve simetriktir. Desteği küçük değildir ve 5/-5 arasında anlamlıdır[37].

3.1.2.3.6 Meyer dalgacı

Meyer dalgacık ailesi frekans uzayında tanımlı, ortonormal dalgacıkları içerir. Bu dalgacık ailesinin matematiksel ifadesi aşağıdaki gibidir.

$$\hat{\psi}(\omega) = \begin{cases} (2\pi)^{-\frac{1}{2}} e^{-\frac{i\omega}{2}} \sin \left[\frac{\pi}{2} v \left(\frac{3}{2\pi} |\omega| - 1 \right) \right], & \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3}, \\ (2\pi)^{-\frac{1}{2}} e^{-\frac{i\omega}{2}} \cos \left[\frac{\pi}{2} v \left(\frac{3}{4\pi} |\omega| - 1 \right) \right], & \frac{4\pi}{3} \leq |\omega| \leq \frac{8\pi}{3}, \\ 0, & \text{diğer durumlarda} \end{cases} \quad (3.11)$$

Buradaki v fonksiyonu aşağıdaki gibidir.

$$v(x) = f(x) = \begin{cases} 0, & x \leq 0 \\ 1, & x \geq 1 \end{cases} \quad (3.12)$$


$$v(x) + v(1 - x) = 1 \quad (3.13)$$

Meyer ölçeklendirme fonksiyonu ise aşağıdaki gibidir.

$$\hat{\phi}(\omega) = \begin{cases} (2\pi)^{-\frac{1}{2}}, & |\omega| \leq \frac{2\pi}{3}, \\ (2\pi)^{-\frac{1}{2}} e^{-\frac{i\omega}{2}} \cos \left[\frac{\pi}{2} v \left(\frac{3}{2\pi} |\omega| - 1 \right) \right], & \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3}, \\ 0, & |\omega| \leq \frac{4\pi}{3} \end{cases} \quad (3.14)$$

Denklemlerden de görülebileceği gibi, bu dalgacık sonlu bir desteğe sahip değildir.

Örnek görüntüsü aşağıdaki gibidir.




Şekil 3.20: Meyer 3(a) Ölçeklendirme fonksiyonu, (b) Dalgacık fonksiyonu.

Bu dalgacık ailesinin desteği sonsuzdur ancak etkili olduğu aralık $[-8 \ 8]$ arasındır. Frekans uzayında tanımlıdır ve simetriktir. Sonsuz türevlenebilir ve süreklidir. Sürekli dönüşüme uygundur ama sonlu dürtü yanıtı (FIR) filtreler temelli bir yakınsama ile ayrık dönüşüm de uygulanabilir[37].



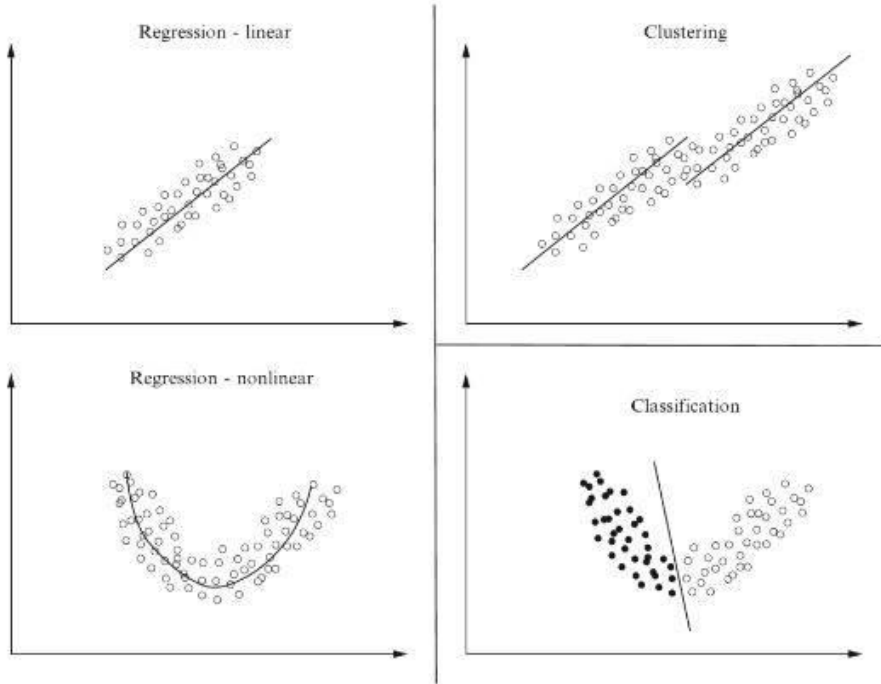
4. MAKİNE ÖĞRENMESİ

Geliştirilen uzman sistem modeline bilişsel psikolojinin sahip olduğu öğrenme yeteneğini mümkün olduğu kadar kazandırmak makine öğrenmesi disiplininin temel amacıdır. Bu durum makine öğrenmesi çalışmalarını hem insanlarda hem de makinelerde öğrenme yeteneği altında yatan süreçleri incelemeye yöneltmektedir. Makine öğrenmesi ile bellek arasında çift yönlü bir ilişki vardır. Bu nedenle yapay zeka araştırmacıları bilgi gösterimi, bellek organizasyonu ve performans ölçütlerin incelenmesi de dolaylı olarak makine öğrenmesi çalışmalarını ilgilendirmektedir. Makine öğrenmesi, daha önceki hesaplama ve tahmin sonuçlarına dair bilgilerinin bellekteki yansımalarını göz önüne alarak gelecekteki olay ve durumları tahmin edebilme yeteneği taşıyan algoritmaların modellenmesini sağlar. Makine öğrenmesi algoritmaları ile geliştirilen uzman sistem modelini veri setlerine uygulama, analiz etme işlemine ise veri madenciliği adı verilir. Makine öğrenmesi ile veri madenciliği arasında organik bir ilişki vardır. Makine öğrenmesi ile sistem eğitilir, veri madenciliği ile ise veri setlerine uygulanır, sonuçlar değerlendirilir ve analiz edilir. Makine öğrenmesi veri'den bilgi çıkarma işiyle ilgilenirken veri madenciliği bu sonuçları yorumlamayla incelemeye ilgilenir. Makine öğrenmesi veri yığınları içinden bilgi çıkarırken bunu en iyi şekilde ve en yüksek performansla yapmak zorundadır. Kullanılan algoritmaların verimi veri setinin karakteristiği ile doğrudan ilgili olduğu için performans analizleri sistemin verimliliği için oldukça önemlidir. Makine öğrenmesi ile istatistik bilimi, veri madenciliği, iş zekası, örüntü tanıma, yapay zekalı sistemler, doğal dil işleme, bilgisayarlı görme, biyoinformatik, robotik, görüntü işleme gibi birçok farklı alan arasında dinamik bir ilişki vardır. Makine öğrenmesi metodlarının masif verilere uygulanması çalışmaları ise veri madenciliği adı altında incelenir.



Şekil 4.1: Verinin bilgiye dönüşüm süreci [53].

Birçok farklı Makine öğrenmesi algoritması vardır ve bunlar farklı şekillerde kategorize edilebilir. En çok bilinen ve en sık kullanılanları gözetimli öğrenme (regresyon ve sınıflandırma) ve gözetimsiz öğrenme (kümeleme) algoritmalarıdır.



Şekil 4.2: Gözetimli/gözetimsiz öğrenme metodlarının örnek gösterimleri.

4.1 Gözetimli Öğrenme

Gözetimli öğrenmeye denetimli veya öğretmenli öğrenme de denmektedir. Gözetimli öğrenmenin kapsamına sınıflandırma ve regresyon girer. Gözetimli öğrenme makine öğrenmesi algoritmaları kullanılarak sisteme tecrübe kazandırılması temeline dayanır. Sadece eğitim verileri eğitilerek sisteme dahil edilir. Sonrasında sistem her defasında yeni öğrenme verilerine tabii tutularak , öğrenmenin genişletilmesi söz konusu olur. Başka bir deyişle sistem tecrübe kazanır. Lineer regresyon, Lojistik regresyon, Destek vektör makineleri, En yakın K-komşu algoritması(k-NN), Karar ağaçları, Lineer Ayırtaç Analizi (Linear Discriminant Analysis), Naive Bayes bu tür öğrenme gösteren algoritmalara örnek verilebilir.

Gözetimsiz öğrenme ise; gözetimli öğrenmedeki gibi giriş verilerine öğreticinin verdiği etiket bilgileri yoktur. Dolayısıyla örüntüyü kümeleme yöntemiyle gruplara ayırır. En sık kullanılan gözetimsiz öğrenme algoritmaları K-merkezli Gruplama (K-Means Clustering) ve Temel Bileşen Analizi (Principal Component Analysis) olarak belirtilebilir. Buna en iyi örnek Kohonen Haritalarıdır.

4.1.1 Lineer regresyon

Regresyon analizi iki ya da daha fazla değişken arasındaki ilişkiyi formüle etmek için kullanılır. Lineer regresyon ise gözetimli bir öğrenme algoritmasıdır. Örnekler ve dahil olduğu sınıf verileri arasında algoritma doğrusal bir ayırım yapar. Başka bir deyişle doğruyu veri seti üzerine uygun şekilde oturtur. Yeni gelen test verilerini de eğitim verilerinin konumlanma parametrelerine göre uygun bölüme yerleştirir. $Y = a + bx$ denklemi bu lineer ilişki formuna örnek olarak verilebilir. Buradaki a ve b regresyon katsayıları, Y değişkeni yanıt değeri, x ise belirleyici değişkendir ve aralarında lineer bir ilişki vardır. Çoklu regresyon örneği olarak ise $Y = a + bx_1 + cx_2$ verilebilir.

Lineer regresyonun hipotezi aşağıdaki gibidir :

$$h_{\theta}(x) = \theta_0 + \theta_1x_1 + \theta_2x_2 + \dots \quad (4.1)$$

Buradaki x_0 değişkeni “bir” varsayılır. Böylelikle denklem şu şekilde yazılabilir.

$$h(x) = \sum_{i=0}^n \theta_i x_i = \theta^T x \quad (4.2)$$

Buradaki θ parametre ve x girdi vektörüdür. Söz konusu denklemde $h(x)$ ve y arasındaki mesafenin küçük olması tercih edildiği için bu mesafeyi minimize etmek adına “en küçük kareler yöntemi” uygulanır.


4.1.2 Lojistik regresyon

Lojistik regresyon y ayrık değişkenini sınıflandırmak için kullanılır. Buradaki amaç bağımsız değişkenlerle bağımlı değişkenler arasındaki ilişkiyi bulmaktır. Değişken sayısına göre binary, ordinal, multinomial olarak adlandırılabilir. Lojistik regresyonda belli bir durum karşılığına bir değer verilmesi sonrası o değer gerçeğe olasılığının tahmini söz konusudur. Lojistik regresyon çıkışı her zaman sıfır ile bir arasında değerler alır. Sonuç değeri olasılık olarak yorumlanır.

Lojistik fonksiyonu $\sigma(t)$ fonksiyonun çıkışı olmak üzere denklem 4.3’teki gibidir.

$$\sigma(t) = \frac{e^t}{e^t + 1} = \frac{1}{1 + e^{-t}} \quad (4.3)$$

Örnek bir lojistik regresyon fonksiyonu grafiği aşağıdaki gibidir:




Şekil 4.3: Standart lojistik fonksiyonu grafiği.

4.1.3 Destek vektör makineleri

Destek vektör makineleri test verilerini geniş marjnlere ayırarak optimal bir model kurar ve bu modele göre test dataları için hedeflenen değerleri tahmin eder. Verileri kategorize eden n boyutlu hiperdüzlem üzerinde çalışır. Bu algoritma istatistiksel model üzerine kurulmuş, yüksek genelleme yeteneğine sahip ve geniş veri setlerine kolay uygulanabilir. Son zamanlarda uzman sistem tasarlamada kullanılan en

popüler algoritmalarından biridir. Sınıflandırma ve regresyon problemlerinde kullanılabilir. Lineer ayrılabilen veriler için ve lineer ayrılamayanlar için farklı varyasyonları mevcuttur.



Şekil 4.4: Lineer olarak ayrılabilen ve ayrılamayan verilerin gösterimi.


DVM algoritmasının en sık bilinen dört çekirdek fonksiyonu vardır. Bunlar doğrusal, polinomyal, sigmoid ve radyal tabanlı fonksiyonlardır.

4.1.4 En yakın k komşu algoritması(k-NN)

K-en yakın komşu algoritması uzaklığa bağlı bir algoritmadır. Veri setindeki verileri birbirine en yakın örnekler üzerinden gruplandırma yaparak sınıflandırma yapar. Belirtilen söz konusu örneklem en yakınındaki k tane verinin sınıfına bakılarak sınıflandırılır. Örneğin k değeri 4 ise sınıflandırılmak istenen veriye en yakın 4 örneğe bakılır ve yeni veri bu örneklerin en fazla dahil olduğu sınıfa dahil edilir. Bu işlem yapılırken sürekli değişkenler için Euclidean, Manhattan ve Minkowski uzaklık fonksiyonları kullanılır ve sınıflı süreksiz değişkenler içinse Hamming mesafesi kullanılır.

Euclidean uzaklık fonksiyonu	$\sqrt{\sum_{i=1}^k (x_i - y_i)^2}$
Manhattan uzaklık fonksiyonu	$\sum_{i=1}^k x_i - y_i $
Minkowski uzaklık fonksiyonu	$\left(\sum_{i=1}^k (x_i - y_i ^q) \right)^{1/q}$
Hamming mesafesi	$\sum_{i=1}^k x_i - y_i $

Çizelge 4.1: Çeşitli uzaklık fonksiyonları ve gösterimleri.



Şelik 4.5: Örnek Knn sınıflandırması gösterimi.

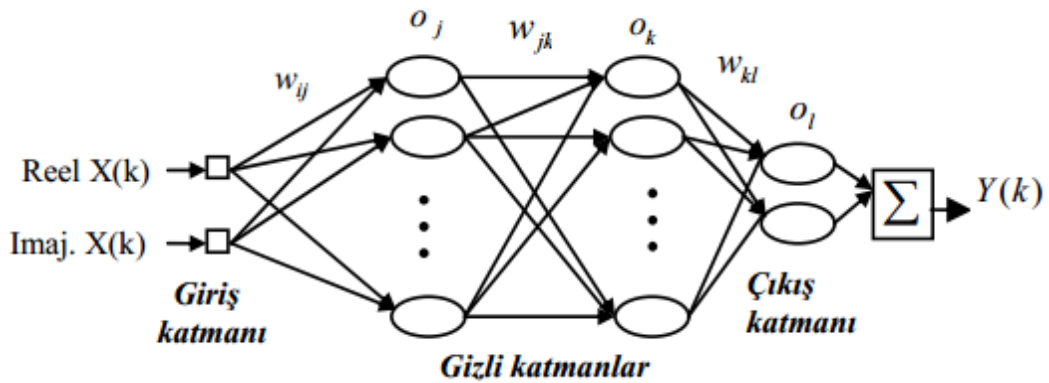
4.1.5. Karar ağaçları

Karar ağaçları veri madenciliğinde sıklıkla kullanılır. Amacı birkaç giriş değişkenine karşın hedef değişkeni tahmin etmektir. Farklı varyasyonları bulunur. Bunlar Rastgele Orman(Random Forest), Hızlandırılmış Ağaçlar (Boosted Trees), Döndürme Ağacı (Rotation Forest), ID3 algoritması, C4.5 algoritması, Chi-Kare Otomatik İlişki Tarayıcısı (Chi-Square Automatic Interaction Detector, CHAID), MARS bunlara örnek olarak verilebilir.

Bu algoritmaların uygulanması ve analizi kolaydır. Veriler ön öşlemlere tabii tutulmalıdır ama bu işlem bu algoritmalarda diğer seçeneklere göre daha az bir iş yükü getirir. Nümerik veya kategorik verilerin her ikisi içinde uygundur bu yönüyle diğer birçok makine öğrenmesi algoritmalarından farklılaşır. Hesaplama yükü ve karmaşıklığı azdır. Basit ve hızlı algoritmasından dolayı masif verileri kısa sürede işleyebilir. Hedef değişkenler sonlu bir dizide ise bu ağaç modellerine sınıflandırma ağaçları, sürekli değişen değerler ise regresyon ağaçları denir.

4.1.6 Çok katmanlı yapay sinir ağı

Yapay sinir ağlarının (YSA) çalışma prensibi biyolojik sinir sisteminin bir parçası olan nöronlar örnek alınarak geliştirilmiştir. Çok katmanlı yapay sinir ağlarında her katmanda en az bir nöron bulunacak şekilde giriş, bir veya birden fazla gizli katman ve çıkış katmanı bulunur. Giriş katmandaki işlemci ara katmanlara sinyal dağıtır; ara katmandaki işlemciler bir önceki katmandan gelen sinyalleri giriş verileri olarak algılar ve ağırlık değerleriyle çarparak her biri bir çıkış değeri üretir. Bu değerler toplanır ve bir transfer fonksiyonundan geçirilerek o nöronun çıkış değeri hesaplanır. Bu işlemler bu kattaki bütün işlemci elemanlar için tekrarlanır. Çıkış katmanındaki işlemciler de bu şekilde işleyerek çıkış değeri üretirler. Bu modellerde veri akışı ileri doğru olduğu için bunlara ileri beslemeli YSA'da denmektedir[49].



Şekil 4.6: Çok katmanlı yapay sinir ağı örneği[50].

YSA içerisinde gerçekleştirilen işlemler sonucunda, çıkış katmanında oluşan sonuç değerleri ile arzulanan sonuçlar karşılaştırılır ve aradaki farka bağlı olarak ağırlık değerleri yeniden düzenlenir. Ağın eğitilmesi sırasında ilk anda ağırlıklar 0 ile 1 arasında rastgele olarak atanır. Bu rastgele atamalardan dolayı çıkıştaki değer ile istenilen sonuç arasında bir hata olacaktır. YSA öğrenme esnasında, oluşan bu hataları kendi içerisinde değerlendirerek, sonuç en az hataya ulaşıncaya kadar bu öğrenme devam edecektir[55].

Çok katmanlı ağların öğrenmesini etkileyen faktörlerden bulunmaktadır. Bunlardan örneklerin seçilmesi, ara katman sayısının belirlenmesi, ağırlık değerlerinin başlangıç

atamaları, örneklerin ağa sunulması, girdi ve çıktıların ölçeklendirilmesi, ağların büyütülmesi ve budanması ağın performansını etkileyen önemli unsurlardır[64].

4.1.7 Naive Bayes Sınıflandırma Algoritması(NB)

Naive Bayes algoritması basit ama etkili bir sınıflandırıcıdır. Her bir verinin hangi olasılık sınıf değerlerine dahil olduğunu hesaplar ve bir olasılık dizisi oluşturur. Bu veriler daha sonra tek bir sınıflandırıcıda sınıflandırılır.

Bağımsız değişkenlerden oluşan bir \mathbf{x} vektörünü $\mathbf{x} = (x_1, \dots, x_n)$ şeklinde ve olası sonuçlar vektörü $C=(C_1, C_2, \dots, C_n)$ olarak gösterilirse; herbiri için $p(C_k|x_1, \dots, x_n)$ hesabı yapılır. Burada n sayısının yüksek olması algoritmanın verimliliğini etkileyebileceği için bu durumlarda koşullu olasılık hesabı yapılabilir. Amaç $P(C_k|x)$ 'i maksimum değere ulaştırmaktır. Eğer nitelikler kategorik ise denklem x 'teki gibi Bayes teoremine göre hesaplama yapılır.

$$p(C_k|\mathbf{x}) = \frac{p(C_k) p(\mathbf{x}|C_k)}{p(\mathbf{x})} \quad (4.4)$$

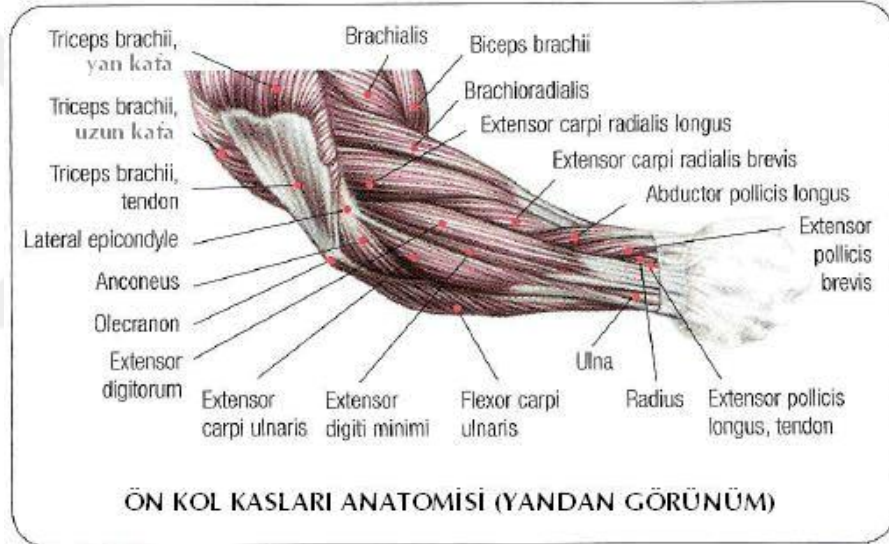
Nitelik nümerik ise (normal dağılım) dizinin Gauss dağılımı gösterdiği varsayılarak (μ ortalama, σ standart sapma) $P(C_k|x)$ denklem y 'deki gibi hesaplanır. $P(C_k|x)$ hesaplanması niteliklerin nümerik veya alfanümerik olma durumlarına göre farklılık gösterir[48].

$$p(x_k|C_i) = g(x_k, \mu_{C_i}, \sigma_{C_i}) \quad (4.5)$$

$$g(x_k, \mu_{C_i}, \sigma_{C_i}) = \frac{1}{\sigma_{C_i} \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x_k - \mu_{C_i}}{\sigma_{C_i}} \right)^2} \quad (4.6)$$


5. MATERYEL VE METOD

Veri seti: Bu çalışma kapsamında kullanılan veri seti ulusal bir veri bankasından alınmış olup yaşları 20-22 arasında değişen 6 sağlıklı kadın ve erkek bireyin gündelik hayatta sıklıkla kullandığı çeşitli nesnelere tutmaya ve kavramaya yönelik 6 farklı el hareketi 30'ar kez tekrar ettirilmesiyile kaydedilen 2 kanallı bir EMG cihazının verilerinden oluşmaktadır[53,54].




Şekil 5.1: Ön kol kaslarının anatomisi.

Veriler Şekil 5.1’de gösterildiği gibi ön kol üzerindeki Flexor Capri Ulnaris ve Extensor Capri Radialis(Longus ve Brevis) kaslarına konumlandırılan yüzey elektrotları aracılığıyla 2 kanalda 300ms süresince 500 Hz sampling rate olacak şekilde kaydedilmiştir. EMG sinyalleri EEG sinyalleri kadar olmasa da gürültüye açık olduğu için veriler gürültülerden arındırılmak adına Butterworth Band geçiren filtren sırasıyla düşük ve yüksek seviyede 15Hz ve 500Hz kullanılarak süzölmüştür.



Şekil 5.2: Silindirik hareket için 1.kanaldan alınan kayıt örneği.


Söz konusu farklı cisimleri tutmaya ve kavramaya yönelik 6 gündelik el hareketi Şekil 5.3'deki gibidir.



Şekil 5.3: Veri setindeki 6 temel hareket.


Gündelik hayatta sıklıkla kullanılan ve veri setimizi oluşturan bu hareket gruplarının sınıfları ve her sınıfa ait örnek EMG sinyalleri aşağıdaki gibidir.

- a) Küresel: Top, elma gibi küresel nesnelere tutmak amaçlı yapılan hareketleri temsil eder.




Şekil 5.4: Küresel hareket için 2 kanaldan kaydedilen örnek EMG sinyali.

- b) Uç: İp gibi küçük nesnelere parmak ucuyla tutmak amaçlı yapılan hareketleri temsil eder.




Şekil 5.5: Uç hareketi için 2 kanaldan kaydedilen örnek EMG sinyali.


- c) Palmar: Kalem, resim fırçası gibi avuca dayandırılan nesnelere kavramak amaçlı yapılan hareketleri temsil eder.



Şekil 5.6: Palmar hareket için 2 kanaldan kaydedilen örnek EMG sinyali.


- d) Lateral: Kredi kartı, kağıt gibi ince, düz nesnelere tutmak için yapılan hareketleri temsil eder.





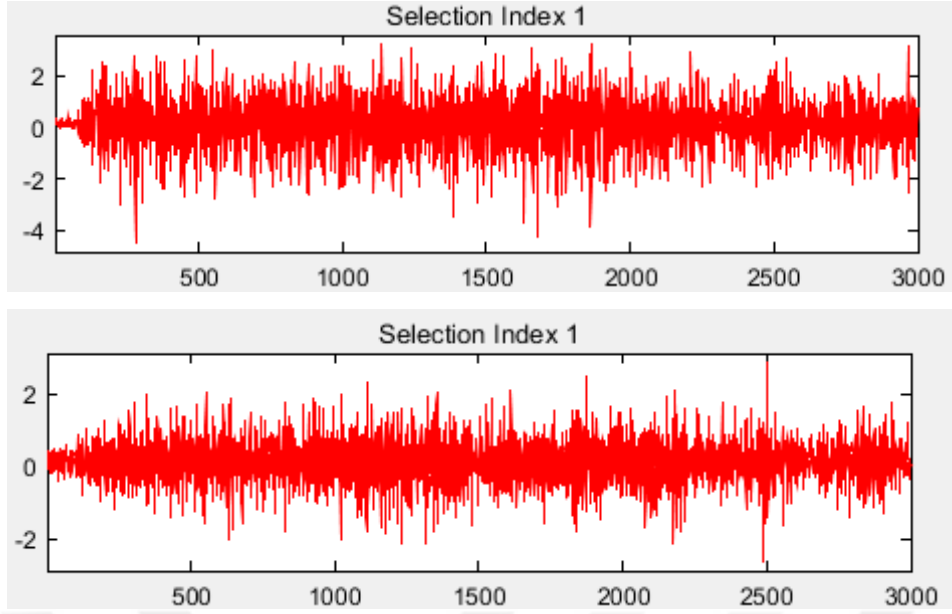
Şekil 5.7: Lateral hareket için 2 kanaldan kaydedilen örnek EMG sinyali.

- e) Silindirik: Bardak, çubuk gibi nesnelere tutmak için yapılan hareketleri temsil eder.




Şekil 5.8: Silindirik hareket için 2. kanaldan kaydedilen örnek EMG sinyali.

- f) Kanca: Bidon gibi ağır yükte kuvvet gerektiren nesnelere tutmak için yapılan hareketleri temsil eder.



Şekil 5.9: Kanca hareket için 2 kanaldan kaydedilen örnek EMG sinyali.




Şekil 5.10: Çalışmanın işlem basamakları.


	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.0722	0.2762	0.4292	0.3272	0.1232	0.0977	0.0722	0.0212	-0.0043	0.1742	0.3782	0.4292	0.2252
2	0.2507	0.3017	0.1997	0.3782	0.0212	-0.0808	-0.1063	0.0212	0.2762	0.0722	-0.6418	0.1997	0.7862
3	0.1232	0.1487	0.1487	0.1232	-0.0043	-0.1573	-0.0298	0.1742	0.1997	0.2507	0.4292	0.3527	0.3272
4	0.5312	-0.1063	-0.2848	-0.3358	-0.1828	0.1232	0.3017	0.3527	0.3272	-0.0298	0.2507	0.4292	-0.0298
5	-0.3103	-0.1828	0.2762	0.4802	0.3527	0.1232	0.1232	0.0977	-0.0298	-0.0808	-0.1828	-0.1063	0.1742
6	0.4037	0.3017	0.1742	-0.0553	-0.1828	-0.2338	-0.2083	0.1232	0.1487	0.2252	0.4037	0.6332	0.6332
7	0.2507	0.3017	0.1232	-0.0553	0.0977	0.1487	0.0212	0.0722	0.1997	0.2507	0.1997	0.1487	0.2252
8	-0.5143	-0.5908	-0.0043	-0.2338	0.2762	0.6077	1.1688	0.9393	-1.2794	-0.4633	0.8117	0.4292	1.1433
9	0.2507	0.2762	0.0467	-0.0298	0.0212	-0.0808	0.0722	0.1487	0.1487	0.3017	0.3527	0.2252	0.2507
10	0.2507	0.2762	0.1487	-0.0298	-0.0808	-0.0298	-0.0298	-0.0808	0.1232	0.2507	0.3272	0.3017	0.3272
11	-0.2083	0.7607	0.9648	-0.0808	-1.5089	-0.4888	-0.1828	0.2762	-0.0553	-0.2593	0.8372	0.2507	0.1232
12	0.7352	0.1487	-0.6929	-0.5908	1.2708	0.5057	0.3782	0.1232	1.9593	0.9393	-5.6147	-2.6055	0.9903
13	0.3782	0.1232	0.0722	0.1487	0.1997	-0.1063	-0.1828	0.0467	-0.0553	0.1997	0.3272	0.3272	0.4037
14	0.1487	0.3782	0.2762	0.1232	0.0977	0.1232	-0.0298	0.0467	0.2507	0.2762	0.3527	0.2252	0.3272
15	0.6332	0.9393	0.4802	1.0158	0.7352	-2.0189	-0.3358	-0.8969	-0.4633	0.3527	1.1433	0.5822	-0.6163
16	-1.3049	0.2762	0.7097	0.3272	0.1232	1.0413	-0.8459	0.4802	-0.0043	-0.6929	0.1997	0.8117	0.3527
17	0.5567	0.7352	0.3017	0.0467	-0.0553	-0.1063	-0.1063	-0.1828	-0.0808	0.0722	0.5057	0.7607	0.5057
18	0.0212	-0.0043	0.1232	0.2252	0.3272	0.1997	0.0977	0.1997	0.1997	0.1997	0.1742	0.2252	0.1232
19	0.0977	0.0212	0.1232	0.1232	-0.0298	0.2252	0.4547	0.8117	0.7862	0.1997	-0.1828	-0.6163	-0.7184
20	0.5822	0.2762	-0.0808	-0.2593	-0.2848	-0.0298	0.0212	0.1487	0.3527	0.4547	0.4292	0.3527	0.0977

Şekil 5.11: Dataset ekran görüntüsü.

Öznitelik vektörü ve sınıflandırma: Yüzey elektrotlarıyla kaydedilen sinyalin analiz edilmesi, karakteristiğinin kesitirimi için özniteliklerinin doğru belirlenip çıkarılması büyük öneme sahiptir. Literatürde EMG sinyallerinin analizi için farklı öznitelik çıkarma yöntemleri denenmiştir. Bunlardan en sık kullanılanları AR katsayıları, Fourier Dönüşüm katsayıları ve Dalgacık dönüşüm katsayılarıdır. Bu çalışmada Markov geçiş matrisine ait katsayıları ve Dalgacık Dönüşüm Katsayıları bir arada kullanılarak öznitelik vektörü oluşturulmuştur. Toplamda her örüntü için 38 adet öznitelik değeri belirlenmiştir ve öğretmenli öğrenme metodları kullanıldığı için 1 adet sınıf verisi eklenmiştir. Ayrık Dalgacık Dönüşümü yapılırken farklı dalgacık ailelerinin EMG sinyallerini temsil yeteneği incelenmiş; performans ve verimlilikleri karşılaştırılmıştır. Öznitelik vektörü belirlendikten sonra elde edilen veri setinin boyutu 900x39'dur. Her bir öznitelik vektöründe için 18 adet Markov katsayısı, 18 adet Dalgacık Dönüşümü katsayısı, 2 adet dalgacık enerjisi verisi ve 1 adet sınıf verisi bulunmaktadır. Markov elemanlarının hesabı MATLAB R2014b Programına yazılan kod ile yapılmıştır. ADD analizleri ise yine MATLAB R2014b Programındaki Wavelet Design & Analysis uygulaması ile yapılmıştır. Veri seti sınıflandırılırken öğretmenli öğrenme algoritmaları kullanılmış olup performans ve verimlilik testleri için WEKA 3.6 kullanılmıştır.



Şekil 5.12: WEKA Programından bir arayüz görüntüsü.



Şekil 5.13: Özniteliklerin sınıf verileriyle ilişkisini gösteren WEKA görüntüsü.

6. BULGULAR

Sınıflandırma işlemleri için çeşitli makine öğrenmesi algoritmalarının performansları incelenmiştir. Bunlardan bazıları Bayes tabanlı Naive Bayes algoritması, Multilayer Perceptron algoritması, Knn- uzaklık tabanlı IBK algoritması, Meta tabanlı Rotation Forest, Kural tabanlı PART algoritması, ve karar ağaçları tabanlı Random Forest algoritmalarıdır.

Veri setindeki toplam örnek sayısı 900 olup eğitim ve test verilerinin oranları %33-%66 olarak seçilmiştir. Cross-validation değeri default olarak 10 alınmıştır.

EMG sinyallerine ait öznitelikler üç farklı şekilde oluşturulmuştur.

1. Markov geçiş matrisi elemanlarından oluşturulan öznitelik vektörü.
2. Ayrık Dalgacık Dönüşümü katsayılarından oluşturulan öznitelik vektörü.
3. Markov geçiş matrisi elemanları ve Ayrık Dalgacık Dönüşümü katsayılarından oluşturulan öznitelik vektörü.

Çizilen çerçeve ışığında yapılan analizlerin sonuçları aşağıdaki çizelgelerdeki gibidir.

Çizelge 6.1: Markov geçiş matrisi elemanlarından oluşan öznitelik vektörlerinin sınıflandırma sonuçları.

Sınıflandırma Algoritması	F-Ölçümü	ROC puanı	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
Naïve Bayes	0.532	0.857	0.452	0.04	54.3333%
Multilayer Perceptron	4.98	0.94	0.7267	4.98	77.2222%
KNN (n=1)	0.838	0.903	0.8067	<0.01	83.8889%
Rotation Forest	0.883	0.987	0.86	1.02	88.3333%
Part	0.744	0.87	0.6933	0.33	74.4444%
Random Forest	0.878	0.988	0.8533	1.37	87.7778%

Çizelge 6.2 : Daubechies dalgacık ailesinin farklı tipleri ile elde edilen katsayılara ait öznelik vektörlerinin sınıflandırma sonuçları.

Dalgacık Türü	Sınıflandırıcı Algoritma	F- Ölçümü	ROC puanı	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
DB4	KNN	0.888	0.933	0.8653	<0.01	88.7778%
DB4	Random Forest	0.905	0.991	0.8867	1.02	90.5556%
DB5	KNN	0.91	0.946	0.892	<0.01	91 %
DB5	Random Forest	0.911	0.993	0.8933	1.05	91.1111%
DB6	KNN	0.912	0.947	0.8947	<0.01	91.2222%
DB6	Random Forest	0.93	0.993	0.916	0.98	93 %
DB7	KNN	0.919	0.951	0.9027	<0.01	91.8889%
DB7	Random Forest	0.91	0.993	0.892	0.95	91 %
DB8	KNN	0.889	0.933	0.8667	<0.01	88.8889%
DB8	Random Forest	0.916	0.993	0.8987	1.22	91.5556%
DB9	KNN	0.898	0.939	0.8773	<0.01	89.7778%
DB9	Random Forest	0.903	0.992	0.884	0.97	90.3333%
DB10	KNN	0.897	0.938	0.876	<0.01	89.6667%
DB10	Random Forest	0.916	0.992	0.8987	1.06	91.5556%

Çizelge 6.3: Db8 dalgacıđı farklı levellerde ayrıştırılarak elde edilen katsayılara ait öznelik vektörlerinin sınıflandırma sonuçları.

Level sayısı	Sınıflandırıcı Algoritma	F-Ölçümü	ROC puanı	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
Level 7	KNN	0.95	0.97	0.94	<0.01	95 %
Level 7	Random Forest	0.952	0.998	0.9427	1.64	95.2222 %
Level 8	KNN	0.942	0.965	0.9307	<0.01	94.2222 %
Level 8	Random Forest	0.953	0.997	0.944	1.34	95.3333 %
Level 9	KNN	0.94	0.964	0.928	<0.01	94 %
Level 9	Random Forest	0.947	0.996	0.936	1.29	94.6667 %
Level 10	KNN	0.918	0.951	0.9013	<0.01	91.7778 %
Level 10	Random Forest	0.934	0.996	0.9213	1.47	93.4444 %

Çizelge 6.4: Ayrık dalgacık dönüşümü analizi ile db8 dalgacıđının 7 level ayrıştırma sonucu elde edilen katsayılara ait öznelik vektörlerinin farklı algoritmalarla sınıflandırma sonuçları.

Sınıflandırma Algoritması	F- Ölçümü	ROC puanı	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
Naïve Bayes	0.405	0.813	0.3147	<0.01	42.8889%
Multilayer Perceptron	0.833	0.962	0.8	5.5	83.3333%
KNN (n=1)	0.95	0.97	0.94	<0.01	95 %
Rotation Forest	0.911	0.991	0.8933	1.18	91.1111%
Part	0.805	0.893	0.7667	0.22	80.5556%
Random Forest	0.911	0.993	0.8933	0.97	91.1111%

Çizelge 6.5: Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşüm katsayıları birlikte kullanılarak oluşturulan öznitelik vektörlerinin KNN algoritması ile farklı n değerlerinde sınıflandırma sonuçları(db8 level7).

N sayısı	F-Ölçümü	ROC puanı	Kappa sayısı	Sınıflandırma Başarısı
1	0.95	0.97	0.94	95 %
2	0.936	0.985	0.9227	93.5556 %
3	0.964	0.993	0.9573	96.4444 %
4	0.954	0.995	0.9453	95.4444 %

Çizelge 6.6: Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşüm katsayıları birlikte kullanılarak oluşturulan öznitelik vektörlerinin çeşitli algoritmalarla sınıflandırma sonuçları(db8 level7).

Sınıflandırma Algoritması	F-Ölçümü	ROC puanı	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
Naïve Bayes	0.568	0.881	0.4973	0.08	58.1111%
Multilayer Perceptron	0.924	0.987	0.9093	10.21	92.4444%
KNN (n=3)	0.964	0.993	0.9573	<0.01	96.4444%
Rotation Forest Part	0.937	0.996	0.924	2.96	93.6667%
Random Forest	0.834	0.911	0.8013	0.39	83.4444%
	0.952	0.998	0.9427	1.19	95.2222%

Çizelge 6.7:Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşümü katsayılarının ayrı ve birlikte çeşitli algoritmalarla sınıflandırma sonuçları(KNN n=1).

Öznitelik Seçimi	Sınıflandırma Algoritması	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
Markov K.	KNN	0.8067	<0.01	83.8889%
A.D.D. K.	KNN	0.892	<0.01	91 %
Markov + A.D.D	KNN	0.94	<0.01	95 %
Markov K.	Random Forest	0.8533	1.29	87.7778%
A.D.D. K.	Random Forest	0.916	1.17	93 %
Markov + A.D.D	Random Forest	0.9427	1.35	95.2222%

Çizelge 6.8: Markov geçiş matrisi elemanları ve ayrık dalgacık dönüşümü katsayılarının ayrı ve birlikte çeşitli algoritmalarla sınıflandırma sonuçları(KNN n=3).

Öznitelik Seçimi	Sınıflandırma Algoritması	Kappa sayısı	Süre (saniye)	Sınıflandırma Başarısı
Markov K.	KNN	0.8107	<0.01	84.2222%
A.D.D. K.	KNN	0.904	<0.01	92 %
Markov + A.D.D	KNN	0.9573	<0.01	96.4444%
Markov K.	Random Forest	0.8533	1.29	87.7778%
A.D.D. K.	Random Forest	0.916	1.17	93 %
Markov + A.D.D	Random Forest	0.9427	1.35	95.2222%

Çizelge 6.9: CfsSubsetEval ile öznelik indirgeme işleminden sonra çeşitli algoritmalar için sınıflandırma sonuçları(KNN n=1).

Öznelik Seçimi	Sınıflandırma Algoritması	Sınıflandırma Başarısı	İndirgeme sonrası
Markov K.	KNN	83.8889%	87 %
A.D.D. K.	KNN	91 %	90.7778 %
Markov + A.D.D	KNN	95 %	96.3333 %
Markov K.	Random Forest	87.7778%	87.3333 %
A.D.D. K.	Random Forest	93 %	91.6667 %
Markov + A.D.D	Random Forest	95.2222%	95.4444 %

Çizelge 6.10: CfsSubsetEval ile öznelik indirgeme işleminden sonra çeşitli algoritmalar için sınıflandırma sonuçları(KNN n=3).

Öznelik Seçimi	Sınıflandırma Algoritması	Sınıflandırma Başarısı	Öznelik indirgeme sonrası
Markov K.	KNN	84.2222%	88.2222 %
A.D.D. K.	KNN	92 %	91.5556 %
Markov + A.D.D	KNN	96.4444%	96.4444 %
Markov K.	Random Forest	87.7778%	87.3333 %
A.D.D. K.	Random Forest	93 %	91.6667 %
Markov + A.D.D	Random Forest	95.2222%	95.4444 %

7. SONUÇLAR VE ÖNERİLER

Bu çalışmada EMG sinyallerinin sınıflandırma verimliliğini artırarak gelecekteki yapılacak protez el çalışmalarına katkı sağlamak amaçlanmıştır. Kullanışlı bir protez el için geniş hareket serbestisi, hızlı tepki süresi, gürültüye dayanıklılık, sistem kaynaklarını verimli kullanma, sinyal analizinin ve sınıflandırma başarısının büyük önemi vardır.

Sinyaller analiz edilirken sinyallerin karakteristiğinin doğru kestirilmesi çalışmanın verimliliği açısından hayattır. Bu çalışmada EMG sinyalinin karakteristiği iki farklı şekilde değerlendirilmiştir. Bunlardan ilki Markov geçiş matrisi elemanlarından oluşan bir öznitelik vektörüdür. Bu veri setine ait sınıflandırma başarımları

Çizelge 6.1'den görüleceği gibi anlamlı fakat yeterli değildir. Bunun yanında Markov geçiş matrisi oluşturmanın sisteme çok işlem yükü getirmemesi, algoritmanın hızlı çalışması ve Çizelge 6.7 ve Çizelge 6.8'den görülen karşılaştırma verilerine göre ana sistemi destekleyici olarak kullanılması fikri oluşturmuştur.

Yapılan analiz sonuçlarında Çizelge 6.1'de gösterildiği gibi Markov geçiş matrisi elemanlarını sınıflandırmada en başarılı 87.7778% doğruluk değeri ile Random Forest ve 88.3333% doğruluk değeri ile Rotation Forest olmuştur. Rotation Forest algoritması 0.35 saniye daha hızlı çalışarak Random Forest algoritmasından daha yüksek doğruluk başarısı sağlamıştır. Bu sonuçlar F-Ölçümü, ROC puanı, Kappa sayısı değerleriyle incelendiğinde anlamlı olduğu görülmektedir. Söz konusu analizde KNN algoritmasında $n=1$ değeri alınmıştır. Farklı n değerlerinde daha anlamlı sonuçlar elde edilebileceği öngörülmektedir.

ADD, EMG sinyallerinin analizinde sıklıkla kullanılır. Yapılan literatür araştırmaları EMG sinyallerinin karakteristiğini yansıtan en iyi dalgacık ailesinin Daubechies dalgacık ailesi olduğunu göstermiştir. Buradan hareketle dalgacık analizlerinde Daubechies dalgacık ailesine ait farklı dalgacık tipleri 8 level ayrıştırılarak KNN ve Random Forest olmak üzere iki farklı makine öğrenmesi algoritması ile performans

analizi yapılmış ve EMG karakteristikleri ile aralarında optimal uygunluk aranmıştır. Çizelge 6.2'den de görüldüğü gibi bu aile EMG sinyalleri ile oldukça uyumlu analiz sonuçları vermektedir. Kendi aralarında en verimli sonuçları veren dalgacıkların 91.1111% doğruluk değeri ile db5, 93% doğruluk değeri ile db6, 91.8889% doğruluk değeri db7 ve 91.5556% doğruluk değeri ile db8 dalgacıkları olduğu görülmektedir. Bunlar arasında Random Forest algoritması ile 93% sınıflandırma başarısı elde edilen db6 dalgacı en verimlisidir. Bunun yanında kullanılan iki algoritmadan uzaklık tabanlı KNN algoritmasının hız performansının oldukça yüksek olması ve buna paralel sınıflandırma başarısının da yüksek olması bu problem için tercih edilebilirliğini arttırmaktadır. Random Forest algoritmasının ise KNN algoritmasına göre yanıt süresi daha uzun olsa da F-Ölçümü, ROC puanı , Kappa sayısı değerleri ile anlamlı sonuçlar verebildiğini gösterdiği için alternatif olarak değerlendirilebilir. Bu analizler dalgacıklar 8 level ayrıştırılarak yapılmıştır. Farklı levellerde farklı sınıflandırma başarıları ile karşılaşılabileceğinden hareketle en verimli olan dalgacık tiplerinin farklı ayrıştırma basamaklarının performans sonuçları da incelenmelidir. Çizelge 6.3'te bununla ilgili bir analiz sonucu gösterilmektedir. Bu çalışma kapsamında yapılan ADD analizi sonucu oluşturulan öznitelik vektörleri kullanılarak yapılan analizlerde en verimli sonuçlar Daubechies dalgacıklarını 7 level ve 8 level ayrıştırılarak elde edilmiştir.

Markov geçiş matrisi elemanları ve ADD katsayıları birlikte öznitelik vektörü olarak kullanıldığında veri setinin EMG karakteristiğini temsil yeteneğinin arttığı ve daha başarılı bir sınıflandırma işlemi yapılabildiği görülmektedir. Markov geçiş matrisi elemanları kullanıldığında KNN algoritması için 84.2222% , Random Forest algoritması içinse 87.7778% sınıflandırma doğruluğu sağlamaktadır. ADD katsayıları kullanıldığında ise KNN algoritması için 92%, Random Forest algoritması için 93% sınıflandırma doğruluğu sağlamaktadır. Buna karşın ikisi beraber kullanıldığında Çizelge 6.7 ve 6.8'de görüldüğü gibi KNN algoritması ile 96.4444%, Random Forest algoritması ile ise 95.2222% sınıflandırma doğruluğu sağlamaktadır. Bu iki öznitelik vektörünün birlikte kullanılmasının sınıflandırma başarısında anlamlı bir artış sağladığı görülmektedir.

Kullanılan makine öğrenmesi algoritmaları özelinde sonuçları değerlendirdiğimizde Çizelge 6.4 ve Çizelge 6.6'da görüldüğü gibi farklı sınıflandırma algoritmaları farklı doğruluk oranlarında sınıflandırma yapmaktadır. Bunlardan en verimliliği vurgulamak gerekirse bunlardan Bayes tabanlı algoritmaların başarısının 50%'nin altında kalarak EMG sinyallerini sınıflandırmada pek başarılı olmadığı söylenebilir. Multilayer Perceptron algoritmasının 83.3333% sınıflandırma başarısı ile anlamlı fakat karmaşık işlem ağı, sisteme getirdiği ek yük ve 5.5 saniye çalışma süresi ile pek verim sağlayamayacağı söylenebilir. Analize konu olan bir diğer algoritma uzaklık tabanlı KNN algoritması ise farklı n değerlerine göre farklı sonuçlar vermekle birlikte tüm n değerleri için 90%'nin üstünde sınıflandırma başarısı sağlayarak anlamlı sonuçlar üretmiştir. Bunun yanında kolay çalışma prensibi, sisteme ek yük getirmemesi ve çalışma süresi olarak 0.1 saniyenin altında olması tercih edilebilirliğini arttırmıştır. Meta algoritmalarından biri olan Rotation Forest algoritması 91.1111% sınıflandırma başarısı ile anlamlı sonuç vermiştir fakat KNN algoritmasına göre daha yavaş çalışması iki algoritma arasında farklılık olarak göze çarpmaktadır. Yine kural tabanlı PART algoritması ile yapılan analiz sonucununun yanıt süresinin 0.2 saniye olması ve 80% olan sınıflandırma başarısı anlamlı ama diğer algoritmalara göre zayıf kaldığı gözlemlenmektedir. Son olarak ağaç tabanlı Random Forest algoritmasının başarısının da 91.1111% gibi yüksek bir oranda olması fakat 0.97 saniye gibi bir işlem süresinin olduğu gözlemlenmektedir. Karşılaştırma yapmak gerekirse uzaklık tabanlı ve ağaç tabanlı algoritmaların diğer algoritmaların bayes tabanlı ve kural tabanlı algoritmalara göre EMG sinyalleri özelinde daha güçlü 90% lerin üzerinde doğruluk sonuçları verdiği görülmektedir. Bunun yanında uzaklık tabanlı algoritmalarından olan KNN algoritmasının kolay bir algoritmasının olması ve n komşu sayısının opsiyonel olarak seçilmesinin yanında 0.1 saniyenin altındaki tepki sürelerinin protez-biyonik el gibi gerçek zamanlı çalışması öngörülen sistemler için tercih edilebilirliğini arttıran bir özellik olarak göze çarpmaktadır.

Veri madenciliği ve makine öğrenmesi çalışmalarında doğru öznelik seçiminin sistemin başarısı için hayati önemi vardır. Analizler sonucu elde edilen 38 özneliğin çok sayıda olmamasına rağmen gerçek zamanlı çalışması arzu edilen bir sistemde hız-işlem yükü ve performans verimliliğini arttırması açısından indirgenebilirlik

özelliđi de test edilmiřtir. Çizelge 6.9 ve Çizelge 6.10'da görüldüđü gibi CfsSubsetEval ile öznitelik indirgeme iřleminden sonraki sınıflandırma verimlilikleri deđerlendirildiđinde 38 özellik taşıyan öznitelik vektörünün 18e indirgenmesinden sonra sistemin iřlem yükü azalsa da sınıflandırma bařarısında anlamlı bir deđişim gözlenmemiřtir. Öznitelikleri indirgeme iřleminin verimi etkilemediđinin gözlemlenmesi EMG kayıtlarına ait olan 900*6000 boyutlarındaki ham sinyal vektörümüzün Markov geçiř matrisi elemanları matrisi ve Ayrık Dalgacık Dönüřümü katsayıları ile güçlü bir temsil yeteneđinin olmasının yanında optimal bir seçim olduđu görülmektedir.

Yukarıda da belirtildiđi gibi sistemin en güçlü sınıflandırma sonuçlarını 0.22 saniyenin altındaki tepki süresi ile Random Forest algoritması ve 0.1 saniyenin altındaki tepki süresi ile KNN algoritmasının vermesi önerilen analiz ve sınıflandırma yöntemlerinin güçlü yanlarını göstermektedir. Verilerin kesinlik ve hassasiyet deđerleri üzerinden ölçülen F-Ölçümü deđeri, dođru pozitiflerin yanlış pozitiflere oranıyla belirlenen ROC puanı deđeri ve deđişkenler arasındaki uyuma güvenilirliđini göstergelerinden olan Kappa sayısı deđerlerinin de 1 deđerine yakın çıkması analiz sonuçlarını güvenilir kılmaktadır.

[55]'daki çalıřmada öznitelik vektörünün belirlenmesinde GMM kullanılmıř olup parmakların sađ-sol-yukarı-ařađı hareketlerin dođru tespitlerinin yüzdeleri 24% ile 95% arasında deđişen dođruluk deđerleri ile sınıflandırılmıřtır.

[56]'deki çalıřmada EMG sinyalleri 7 farklı el hareketi için yapay sinir ađları kullanılarak 95% dođruluk deđeri ile sınıflandırılmıřtır.

[57]'de 6 hareket sınıfı el açık/kapalı, bilek germe/bükme, bilek içe/dıřa döndürme hareketleri Doğrusal ayrıřtırma analizi uygulanarak 4 kanaldan yaklaşık 85% dođruluk deđeri ile sınıflandırılmıřtır.

[58]'da Gauss karıřımı modeli ile 10 el hareketi 5 kanaldan 90%, Destek Vektör Makineleri ile 94% dođruluk deđeri ile sınıflandırılmıřtır.

[59]'da Hızlı Fourier Dönüřümü katsayıları kullanılarak 7 el hareketi 4 kanaldan Yapay sinir ađları ile 90% dođruluk deđeri ile sınıflandırılmıřtır.

[18]'de sEMG sinyalinin modellenmesinde EM (expectation maximization) algoritması ile beraber AR,ARMA,ARIMA,WAMP, RMS, MUAP ve GMM modellerinin farklı ikili kombinasyonlarının veri kümesini temsil yetenekleri kıyaslanmıştır. Sınıflandırma algoritması olarak back propagation (BP) ve support vector machine (SVM) incelenmiş ve ortalama % 93 sınıflandırma başarımı elde edilmiştir.

[21] 'de EMG sinyallerini sınıflandırmak için 6 temel hareketi içeren bir bulanık mantık çıkarım sistemi önerilmiştir. Bu çalışmada tasarlanan ve kullanılan bulanıkmantık sistemleri, bağımsız olarak ve hem zaman hem de zaman-frekans özellikleri için karma bir biçimde test edilmiştir. Bu birleşik yaklaşım için sistemin ortalama hassasiyetinin %96 olduğu bildirilmiştir.

[14]'de el hareketi komutlarını tanımlamak için uyarlanabilir neuro-fuzzy çıkarım sistemi önerilmiştir ve eğitim için hybrid bir algoritma ile ortalama 92% doğruluk değeri ile sınıflandırılmıştır.

Bu çalışma kapsamında EMG sinyallerinin öznel vektörlerinin oluşturulması için önerilen Markov geçiş matrisi elemanları ve Ayrık Dalgacık Dönüşümü katsayılarının; 6 temel el hareketine ait veri setinin uzaklık tabanlı KNN algoritması 96.4444% ile sınıflandırılması, sınıflandırma verimliliğini, ROC puanı, Kappa sabiti, F ölçümü ve algoritmanın işleyiş süresinin 0.1 saniyenin altında olması ile değerlendirildiğinde gerçek zamanlı sistemler için gereken hızlı yanıt verme özelliğini taşımasının yanında güçlü temsil yeteneğinin olduğu da görülmektedir.

EMG sinyali karakteristik kestirimi protez-biyonik kolların geliştirilmesine yardımcı olmasının yanında robot kolların gerçeğe uygun geliştirilmesinde, kesik uzuvların yerine dikilmesinde veya klinik teşhislerin belirlenmesine de yardımcı olduğu bilinmektedir. Bu çalışma da kullanılan metodlarla EMG sinyallerinin karakteristik kestirimini ve sınıflandırma başarısını ve performansını artmasına katkı sağlanmaya çalışılmıştır. Elde edilen sonuçlar ve önerilen metodların yeni çalışmalara katkı sağlayacağı düşünülmektedir.

EMG gibi durağan olmayan sinyallerin hem zaman domeninde hemde frekans domeninde analizinin önemli olması Ayrık Dalgacık Dönüşümünün bu işlem için

uygun olduğunu göstermektedir. Verimli bir sınıflandırma için doğru hareket için doğru kas gruplarının seçilmesi de hayati önem taşır. Bunun yanında protez- biyonik kol çalışmalarının gerçek zamanlı uygulamaları incelendiğinde halen gerçek el yeteneklerine göre oldukça zayıf olduğu görülmektedir. Bu alanda yapılacak çalışmaların daha çok sayıda hareket sınıfları içeren veri setleri ile geliştirilmesi gerekmektedir. Bunu yaparken gerçek zamanlı kullanılacağı için söz konusu sinyalin gürültülere karşı dirençli olması ve gereken ayrıştırmaların optimal yapılması konusunda da çalışmalar devam etmelidir. Yine söz konusu sistemlerin gündelik hayatta kullanılması hedeflendiği için tepki süresi hayatidir. Bu yüzden öznitelik vektörlerini optimal seçip, sınıflandırma doğruluğu, hassasiyet, güvenilirlik, duyarlılık gibi parametrelerin maximize ve tepki süresi, işlem yükü gibi parametrelerin ise minimize edilmesi gerekmektedir.

KAYNAKÇA

- [1] **Brockwell,P.J., and Davis,R.A.,** 2009, Time Series: Theory and Methods, Springer.
- [2] **Bu, N., Fukuda, O., and Tsuji, T.,** 2003, EMG-based motion discrimination using a novel recurrent neural network, *J.Intell. Inf. Syst.* 21 (2), p:113–126.
- [3] **Dong, H., Wang, Z., Ho, D.W.C., Gao, H.,** 2011, Robust H1 filtering for Markovian jump systems with randomly occurring nonlinearities and sensor saturation: the finite-horizon case, *IEEE Trans. Signal Process.* 59 (7), pp. 3048–3057.
- [4] **Dong, H., Wang, Z., Gao, H.,** 2012, Fault detection for Markovian jump systems with sensor saturations and randomly varying nonlinearities, *IEEE Trans. Circuits Syst. I: Reg. Pap.* 59 (10), pp. 2354–2362.
- [5] **Monsifrot,J., Le Carpentier, E., Aoustin, Y., Farina, D.,** 2014, Sequential decoding of intramuscular EMG signals via estimation of a Markov model, *IEEE Trans. Neural Syst. Rehab. Eng.* 22 (5), pp. 1030–1040.
- [6] **Dideriksen, J.L., Gianfelici, F., Maneski, L.Z.P., Farina, D.,** 2011, EMG-based characterization of pathological tremor using the iterated Hilbert transform, *IEEE Trans. Biomed. Eng.* 58 (10), pp. 2911 –2921.
- [7] **Ouyang, G., Zhu, X., Ju, Z., Liu, H.,** 2014, Dynamical characteristics of surface EMG signals of hand grasps via recurrence plot, *IEEE J. Biomed. Health Inform.* 18 (1), pp. 257–265.
- [8] **Dideriksen, J.L. , Enoka, R.M., Farina, D.,** 2011, A model of the surface electromyogram in pathological tremor, *IEEE Trans. Biomed. Eng.* 58 (8), pp. 2178–2185.
- [9] **Kitamura, T., Tsujiuchi, N., Koizumi, T.,** 2008, Hand motion estimation by EMG signals using linear multiple regression models, in: *Proceedings of the 28th IEEE In Engineering in Medicine and Biology Society Annual International Conference*, New York, USA, pp. 1339–1342.
- [10] **Jiang, N., Dosen, S., Müller, K.R., Farina, D.,** 2012, Myoelectric control of artificial limbs. Is there a need to change focus? *IEEE Signal Process. Mag.* 29 (5) pp. 149–152.
- [11] **Graupe, D., Cline, W.K.,** 1975, Functional separation of EMG signals via ARMA identification methods for prosthesis control purposes, *IEEE Trans. Syst. Man Cybern.* 5 (2), pp. 252–259.
- [12] **Khezri, M., Jahed, M.,** 2011, A neuro-fuzzy inference system for sEMG-based identification of hand motion commands, *IEEE Trans. Ind. Electron.* 58 (5), pp. 1952–1960.
- [13] **Ahmad, S.A., Chappell, P.H.,** 2007, Surface EMG Classification Using Moving Approximate Entropy. *International Conference on Intelligent and Advanced Systems*, pp.1163-1167.
- [14] **Khezri , M., Jahed, M., Sadati, N.,** 2007, Neuro-Fuzzy Surface EMG Pattern Recognition for Multifunctional Hand Prosthesis Control. *IEEE*, pp. 269-274.
- [15] **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, pp. 169-174.
- [16] **Oskoei, M.A., Hu, H.**, 2007, Myoelectric Control Systems. Biomedical Signal Processing and Control, pp.2:275-294.
- [17] **Oskoei M.A., Hu H.**, 2008, Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb, IEEE Transactions on Biomedical Engineering, Vol. 55, No. 8.
- [18] **Lu, Y., Ju, Z., Liu, Y., Shen, Y., Liu, H.**, 2015, Time series modeling of surface EMG based hand manipulation identification via expectation maximization algorithm, Neurocomputing 168, pp. 661–618.
- [19] **Klieger, D.M.**, 2010, Saunders Essentials of Medical Assisting.
- [20] **DiGiovanna, A. G.**, 2000, Biology of aging in humans , The McGraw-Hill Companies, New York .
- [21] **MacDonald, P.E., Rorsman, P.**, (February 2006), *Oscillations, intercellular coupling, and insulin secretion in pancreatic beta cells*, *PLoS Biol.* **4** (2): e49. doi:10.1371/journal.pbio.0040049. PMC 1363709. PMID 16464129.
- [22] **Kamen, G.**, 2004, Electromyographic Kinesiology. In Robertson, DGE et al. Research Methods in Biomechanics. Champaign, IL: Human Kinetics Publ.
- [23] **Şenli, K.**, 2011, EMG(Elektromiyografi) Kontrolü Protez Kol Tasarımı, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü.
- [24] **Yazgan, E. ve Korürek, M.**, 1996, Tıp Elektroniği, İstanbul Teknik Üniversitesi Elektrik-Elektronik Fakültesi Ofset Baskı Atölyesi.
- [25] **Arslan, E.**, 2008, Emg İşaretlerinin İncelenmesi Ve Veri Madenciliği Uygulaması, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- [26] **Bozkurt, M.R.**, 2007, "EMG İşaretlerinin Modern Yöntemlerle Önışlemesi ve Sınıflandırılması", Sakarya Üni. , Fen Bilimleri Enstitüsü, Doktora Tezi, Sakarya.
- [27] **Shin, J.O.**, 2003, Clinical Electromyography: Nerve Conduction Studies.Lippincott Williams & Wilkins.Philadelphia.
- [28] **Başpınar, U.**, 2014,“Elektromiyogram Sinyallerinin Sınıflandırılması Ve Bağımsız Bileşen Analizi İle İşlenmesi”, Doktora Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [29] **De Luca, C. J.; Forrest, W. J.**,1973, Some Properties of Motor Unit Action Potential Trains Recorded During Constant Force Isometric Contractions in Man. Kybernetik, 12, pp. 160-168.
- [30] **De Luca, C. J.**, 1979, Physiology and Mathematics of Myoelectric Signals. Biomedical Engineering, IEEE Transactions on, pp. 313-325.
- [31] **Reaz, M.; Hussain, M.; Mohd-Yasin, F.**, 2006, Techniques of Emg Signal Analysis: Detection, Processing, Classification and Applications. Biological procedures online, 8, pp. 11-35.
- [32] **Parker, P. A.; Scott, R.**, 1986, Myoelectric Control of Prostheses. Critical reviews in biomedical engineering, 13, pp. 283.
- [33] **Yazıcı, İ.**, 2008, “Emg İşaretlerinin İşlenmesi Ve Sınıflandırılması”, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.

- [34] **Reaz, M.; Hussain, M.; Mohd-Yasin, F.**, 2006, Techniques of Emg Signal Analysis: Detection, Processing, Classification and Applications. Biological procedures online, 8, pp. 11-35.
- [35] **Demir Ö.**, 2008, EEG Dalgalarının Wavelet (Dalgacık) Dönüşümü ile Değerlendirilmesi, Tez (Yüksek Lisans), Dumlupınar Üniversitesi.
- [36] **Sezer E.**, 2008, Eilepsi Teşhis için EEG Sinyal Analizi, Yüksek Lisans Tezi, Selçuk Üniversitesi.
- [37] **Akıllı M.**, 2013, EEG Zaman Serilerinde Zayıf Sinyaller, Doktora Tezi, İstanbul Üniversitesi.
- [38] **Demren E.**, 2015, Dalgacık Dönüşümünün Fourier Dönüşümü ile Karşılaştırılması ve Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi.
- [39] **Misiti, M., Misiti, Y., Oppenheim, G., ve Poggi, J. M.**, 2004, User's Guide on Wavelet Toolbox 4 for MATLAB. Matworks Incooperation.
- [40] **Abbak R. A.**, 2007, Jeodezide Zaman Serilerinin Dalgacık Analizi, Doktora Semineri, Selçuk Üniversitesi.
- [41] **Cox, D.R. and Miller, H.D.**, 2001, The Theory Of Stochastic Processes, New York.
- [42] **Jazwinski, A.H.**, 2007, Stochastic Processes and Filtering Theory, Mineola, New York.
- [43] **Fugal, D.L.**, 2009, Conceptual Wavelets in Digital Signal Processing,.
- [44] **Gonzales, R.C.; Woods, R.E.**, 2001, "Digital Image Processing", 2nd Edition, ABD, ISBN: 0-13-094650-8, 1-750.
- [45] **Chen, C.F.; Hsiao, C.H.**, 1997, "Haar Wavelet Method for Solving Lumped and Distributed-Parameter Systems", Proceedings of IEEE, *Control and Theory Applications*, Vol. 144, No 1, pp. 87-94.
- [46] **Çelik E.**, 2011, Görüntü İşlemeye Dayalı Avuç İçi İzinin Yapay Sinir Ağı İle Tanınması, Marmara Üniversitesi, Fen bilimleri enstitüsü, Yüksek Lisans tezi.
- [47] <http://www.math.rutgers.edu/courses/338/coursenotes/chapter5.pdf> erişim tarihi: 19.04.2016 saat: 15:10.
- [48] **Freedman. D. A.**, 2009, İstatistiksel Modeller: Teori ve Uygulama, Cambridge University Press, p.pp. 128. 128.
- [49] **Kartal. E.**, 2015, Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri Ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama- Doktora tezi- İstanbul Üniversitesi- Fen bilimleri enstitüsü.
- [50] **Seyman, M.N., Taşpınar. N.**, 13–15 Mayıs 2009, Çok Katmanlı Yapay Sinir Ağları Kullanarak Ofdm Sistemlerinde Kanal Dengeleme- 5. Uluslar arası İleri Teknolojiler Sempozyumu (IATS'09), Karabük, Türkiye.
- [51] **Öztemel, E.**, 2012, Yapay Sinir Ağları, Papatya yayıncılık.
- [52] **Özkan, Y.**, 2008, Veri Madenciliği Yöntemleri, Papatya Yayıncılık, İstanbul.
- [53] **Çağiltay, N.**, 2010, İş Zekası ve Veri Ambarı Sistemleri / Odtü / Bilgisayar Dizisi.
- [54] **Sapsanis, C., Georgoulas, G., Tzes, A., Lymberopoulos, D.**, 2013, Improving EMG based classification of basic hand movements using EMD, 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 13 (EMBC 13), July 3-7, pp. 5754 – 5757.

- [55] **Sapsanis, C.**, 2014, ‘Recognition of basic hand movements using electromyography.
- [56] **Erol, C.**, 2012, Yapay Zeka Denetimi ile Emg Sinyallerinin İşlenmesi Ve Sınıflandırılması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [57] **Güvenç, S.A.**, 2014, Ön Kol Yüzey Emg Sinyallerinin Örüntü Tanıma Tabanlı Analizi Ve Yapay Sinir Ağları İle Sınıflandırılması- Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- [58] **Hargrove, L.J., Scheme, E.J., Englehart, K.B., and Hudgins, B.**, 2010, Multiple binary classifications via linear discriminant analysis for improved controllability of a powered prosthesis, *IEEE Trans. Neural Syst. Rehabil. Eng.*, 18, 1, pp. 49-57.
- [59] **Ju, Z., Ouyang, G., Wilamowska-Korsak, M. and Liu, H.**, 2013, Surface EMG Based Hand Manipulation Identification Via Nonlinear Feature Extraction and Classification, *Sensors Journal IEEE*, 13, 9, pp. 3302 – 3311.
- [60] **Oyama, T., Mitsukura, Y., Karungaru, S.,G., Tsuge, S. and Fukumi, M.**, 2009, Wrist EMG signals identification using neural network, In 2009 35th Annual Conference of IEEE Industrial Electronics, *Bildiriler Kitabı*: pp. 4286-4290.
- [61] **Castellini, C., Van der Smagt, P., Sandini, G., 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.
- [62] **Chan, A.D.C., Green, G.C.**, 2007, Myoelectric control development toolbox, in: *Proceedings of the 30th Conference of the Canadian Medical & Biological Engineering Society, Toronto, CA, USA*.
- [63] **Chen, W., Wang, Z., Xie, H., Yu, W.**, 2007, Characterization of surface EMG signal based on fuzzy entropy, *IEEE Trans. Neural Syst. Rehab. Eng.* 15 (2), pp. 266–272.
- [64] **Ghasemzadeh, H., Jafari, R., Prabhakaran, B.**, 2010, A body sensor network with electromyogram and inertial sensors: multimodal interpretation of muscular activities, *IEEE Trans. Inf. Technol. Biomed.* 14 (2), pp. 198-206.
- [65] **Inoussa, G., Peng, H., Wu, J.**, 2012, Nonlinear time series modeling and prediction using functional weights wavelet neural network-based state-dependent AR model, *Neurocomputing* 86 (1 –2), pp. 59–74.
- [66] **Reaz, M., Hussain, M., Mohd-Yasin, F.**, 2006, Techniques of EMG signal analysis: detection, processing, classification and applications, *Biol. Proced. Online* 8 (1), pp. 11–35.
- [67] **Soares, A., Andrade, A., Lamounier, E., Carrijo, R.**, 2006, The development of a virtual myoelectric prosthesis controlled by an EMG pattern recognition system based on neural networks, *J. Intell. Inf. Syst.* 21 (2) , pp. 127-141.

ÖZGEÇMİŞ



Ad Soyad: Duygu BAĞCI

Doğum Yeri ve Tarihi: Gaziantep 1988

Adres: DEU- Bergama MYO Lojmanları

E-Posta: duygu.bagci@deu.edu.tr

Lisans: Mersin Üniversitesi

Mesleki Deneyim:

2011-2013: Milli Eğitim Bakanlığı- Öğretmen

2013-2016: Dokuz Eylül Üniversitesi – Bergama MYO / Öğretim Görevlisi

Yayın ve Patent Listesi:

- 1- **Güntekin, M., Akbaş, A., Bağcı, D., Erkyaman. D.**, 2013, QoS Based a Novel Framework for Cloud Service Monitoring and Discovery in IaaS Level, 1st International Symposium on Digital Forensics and Security, Fırat University.
- 2- **Ataç S., Bağcı D.**, 2015, EPUB: Reflowable,accessible,interactive and open source file format for electronic publications in lifelong learning, International Conference on Best Practices and Innovations in Education.

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR

- 1- **Bağcı. D., Koçal. O.H.**, 2016, Protez- Biyonik El Kontrolü için EMG İşaretlerinin Makine Öğrenmesi Metotlarıyla Sınıflandırılması, XVIII. Akademik Bilişim Konferansı, Aydın, Turkey.