

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**ÖN KOL YÜZEY EMG SİNYALLERİNİN ÖRÜNTÜ TANIMA TABANLI  
ANALİZİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**Seyit Ahmet GÜVENÇ**

**EKİM 2014  
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**ÖN KOL YÜZEY EMG SİNYALLERİNİN ÖRÜNTÜ TANIMA TABANLI**  
**ANALİZİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI**

**Seyit Ahmet GÜVENÇ**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde**  
**"YÜKSEK LİSANS (BİLGİSAYAR MÜHENDİSLİĞİ)"**  
**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 09.09.2014**  
**Tezin Savunma Tarihi : 02.10.2014**

**Tez Danışmanı : Doç. Dr. Mustafa ULUTAŞ**

**Trabzon 2014**

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalında  
Seyit Ahmet Güvenç tarafından hazırlanan

ÖN KOL YÜZEY EMG SİNYALLERİNİN ÖRÜNTÜ TANIMA TABANLI  
ANALİZİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

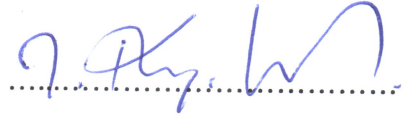
başlıklı bu çalışma, Enstitü Yönetim Kurulunun 16 / 09 / 2014 gün ve 1570 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda

YÜKSEK LİSANS TEZİ

olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Temel KAYIKÇIOĞLU



Üye : Doç. Dr. Mustafa ULUTAŞ



Üye : Yrd. Doç. Dr. Bekir DİZDAROĞLU



Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

## ÖNSÖZ

Günümüzde Elektromiyografi (EMG) sinyalleri kullanılarak yönetilebilen yapay uzuvlar ile ilgili birçok çalışma yapılmaktadır. Bu çalışmalarda, yapay uzvun hem gerçek zamanlı cevap verebilmesi hem de çok fonksiyonlu olabilmesi, üzerinde çalışılan önemli problemlerdendir. Çalışmamda yapay uzuvların çok fonksiyonlu olabilmesine katkı sağlamak amacıyla farklı el ve kol hareketlerine ait EMG sinyalleri işlenerek bu hareketlerin sınıflandırılmasına çalışılmıştır.

Bu tezin hazırlanmasında danışmanlığımı üstlenerek her türlü desteği veren hocam Doçent Dr. Mustafa Ulutaş'a, yardımlarını esirgemeyen arkadaşım Mengü Demir'e, beni yetiştirip bugünlere gelmemde büyük emekleri olan ve haklarını hiçbir zaman ödeyemeyeceğim annem, babam ve babaanneme, manevi desteklerini esirgemeyen kardeşim ve ağabeyime sonsuz teşekkürlerimi sunarım.

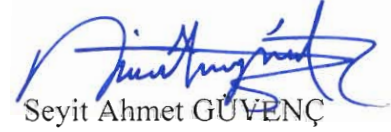
Bu çalışmayı desteğini hep yanımda hissettiğim değerli eşim Ayşen'e ithaf ederim.

Seyit Ahmet GÜVENÇ

Trabzon 2014

## TEZ BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Ön Kol Yüzey Emg Sinyallerinin Örüntü Tanıma Tabanlı Analizi Ve Yapay Sinir Ağları İle Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Doçent Dr. Mustafa ULUTAŞ’ın sorumluluğunda tamamladığımı, verileri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 30/10/2014



Seyit Ahmet GUVENÇ

## İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ .....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZGEÇMİŞ.....	VII
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ.....	XIII
1. GENEL BİLGİLER .....	1
1.1. Giriş ve Çalışmanın Amacı .....	1
1.2. EMG İşaretlerinin Oluşumu ve Özellikleri.....	4
1.3. EMG Sinyallerinin Elde Edilmesinde Kullanılan Yöntemler.....	6
1.3.1. İğne Elektrot Kullanarak EMG Sinyalinin Elde Edilmesi .....	7
1.3.2. Yüzey Elektrot Kullanarak EMG Sinyalinin Elde Edilmesi.....	7
1.3.3. Hedef Kas Sinirinin Yeniden Bağlanması Yöntemi .....	8
1.4. EMG Sinyallerinin Elde Edilmesi ve Kaydedilmesi .....	9
1.4.1. Sinyalin Yükseltilmesi .....	9
1.4.2. Sinyalin Sayısallaştırılması .....	11
1.5. Örüntü Tanıma Tabanlı Yaklaşımda EMG Sinyallerinin Ön İşlenmesi .....	13
1.5.1. Gürültü Giderme .....	13
1.5.1.1. Geleneksel Gürültü Giderme .....	14
1.5.1.2. Dalgacık Dönüşümü ile Gürültü Giderme .....	14
1.5.2. Sinyalin Bölütlere Ayrılması .....	18
1.5.2.1. Geçici Durum ve Kalıcı Durum Bileşenleri.....	18
1.5.2.2. Pencereleme .....	19

1.6.	EMG Sinyallerinin Öznitelikleri.....	20
1.6.1.	Zaman Düzlemi Öznitelikler.....	21
1.6.2.	Zaman-Frekans Düzlemi Öznitelikler.....	27
1.6.2.1.	Sürekli ve Ayrık Dalgacık Dönüşümü.....	28
1.6.2.2.	Dalgacık Katsayıları Öznitelikleri .....	33
1.6.2.2.1.	Dalgacık Katsayıları Ortalama Mutlak Değeri .....	33
1.6.2.2.2.	Dalgacık Katsayıları Eğim Gösterge Değişikliği.....	34
1.7.	Sınıflandırma.....	34
1.7.1.	Yapay Sinir Ağları (YSA).....	35
1.7.1.1.	Yapay Sinir Hücresi Modeli .....	36
1.7.1.2.	Çok Katmanlı Yapay Sinir Ağları (ÇKYSA) .....	38
1.7.1.3.	İleri Beslemeli ve Geri Beslemeli Yapay Sinir Ağları.....	39
1.7.1.4.	Yapay Sinir Ağlarında Öğrenme Yöntemleri .....	40
1.7.1.5.	Yapay Sinir Ağlarında Öğrenme Algoritmaları.....	40
1.7.1.5.1.	Geri Yayılım Algoritması .....	41
2.	YAPILAN ÇALIŞMALAR VE BULGULAR.....	44
2.1.	EMG Sinyallerinin Elde Edilmesinde Kullanılan Donanımlar.....	45
2.2.	EMG Sinyallerinin Elde Edilmesi .....	47
2.2.1.	Kayıtlar Alınırken Uygulanan Protokol.....	49
2.2.2.	Sayısal Ortama Aktarma ve Kayıt .....	53
2.3.	EMG Sinyallerinin Ön İşlemlerden Geçirilmesi.....	55
2.3.1.	Sayısal Filtreler ile Gürültü Giderme.....	55
2.3.2.	Kalıcı Durum Sinyallerinin Seçilmesi ve Bitişik Pencereleme .....	56
2.4.	Özniteliklerin Çıkartılması.....	57
2.5.	Bazı Özniteliklerin Eşik Değeri Parametrelerinin Belirlenmesi .....	59
2.5.1.	Sıfır Geçiş Tespit Sayısı (SGTS) Özniteliği Eşik Değerinin Belirlenmesi.....	59
2.5.2.	Willision Genliği (WG) Özniteliği Eşik Değerinin Belirlenmesi.....	61

2.5.3.	Eđim Gösterge Deęişiklięi (EGD) Öznitelięi Eşik Deęerinin Belirlenmesi .....	63
2.6.	EMG Verilerinin Sınıflandırılması .....	65
2.6.1.	Öznitelik Matrisi ve Örneklerin Aęa Sunulması .....	66
3.	TARTIŞMA VE SONUÇLAR .....	68
3.1.	Zaman Düzlemi Öznitelikleri ve AR Katsayılarıyla İlgili Sonuçlar.....	68
3.1.1.	AR Katsayıları Sınıflandırma Sonuçları .....	68
3.1.2	AR Katsayılarının Farklı ZD Öznitelikleri Birleşimlerinin Sonuçları.....	69
3.1.3.	Zaman Düzlemi Öznitelikleri ve ZD+AR Katsayılarıyla İlgili Sonuçlar .....	70
3.2.	Dalgacık Katsayıları Öznitelikleriyle İlgili Sonuçlar.....	72
3.3.	ZD ve ZFD Öznitelik Gruplarının Birleşimiyle Elde Edilen Sonuçlar.....	74
3.4.	Elde Edilen Dięer Sonuçlar.....	76
4.	ÖNERİLER.....	70
5.	KAYNAKLAR .....	79
6.	EKLER.....	84

## ÖZGEÇMİŞ



## Yüksek Lisans Tezi

### ÖZET

#### ÖN KOL YÜZEY EMG SİNYALLERİNİN ÖRÜNTÜ TANIMA TABANLI ANALİZİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

Seyit Ahmet GÜVENÇ

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Doç. Dr. Mustafa ULUTAŞ  
2014, 83 Sayfa, 13 Sayfa Ek

Aktif elektrotlar, yüksek başarılı işlemciler ve yüksek enerji yoğunluklu bataryaların kullanımı ile engelli kişiler için bir çok farklı protez üretimi, bu konuda sürekli artan bir talep oluşmaktadır. El, hastaların cisimleri kullanabilme için gereken karmaşık hareketleri yapabildiği için bu uzuvların en önemlilerinden biridir. Fakat, yüksek hareket serbestliği sağlayan çoklu eklem ve kaslardan oluştuğu için protez el tasarımı kolay değildir.

Bu tezde, sınıflayıcı algoritmaları çalıştıran işlemci çıkışındaki karmaşık hareket etiketleri ile denetlenen başarılı protez el yapımındaki ilk iki adım olan Elektromiyografik (EMG) işaretlerin alınması ve sınıflandırılması üzerine yoğunlaşmıştır. Gönüllülerin 7 temel el hareketi sırasında ön kollarındaki yüzey elektrotları ile fleksör ve extensör kaslarına ait EMG işaretleri alınarak, yükseltilmiş, sayısallaştırılmış ve işlenmek üzere bilgisayara aktarılmıştır. Çeşitli zaman ve zaman-frekans özellikleri sınıflandırılmadan önce, EMG işaretleri filtrelenmiş ve ön-işlemlere tabii tutulmuştur. Zaman ve zaman-frekans özellikleri kombinasyonları, örnekleri sınıflamak için kullanılan bir Yapay Sinir Ağı'nın (YSA) eğitimi için kullanıldıktan sonra, eğitilen YSA'nın sınıflama başarımı hem eğitim kümesi hem de test kümesi için çıkarılmış ve diğer önemli bulgular ile birlikte rapor edilmiştir.

**Anahtar Kelimeler:** EMG sinyalleri, Miyoelektrik Kontrol Sistemleri, Elektromiyografi, EMG öznitelikleri, Yapay Kol, Yapay Sinir Ağları.

Master Thesis

SUMMARY

PATTERN RECOGNITION BASED ANALYSIS OF FOREARM SURFACE EMG  
SIGNALS AND CLASSIFICATION WITH ARTIFICIAL NEURAL NETWORKS

Seyit Ahmet GÜVENÇ

Karadeniz Technical University  
The Graduate School of Sciences  
Computer Engineering Graduate Program  
Supervisor: Assoc. Prof. Mustafa ULUTAŞ  
2014, 83 Pages, 13 Pages Appendix

There is an ever-growing demand for prosthetic limbs as active electrodes, high performance processors and high-energy density batteries are used to make wide variety of limbs for disabled people. One of the most significant limbs is prosthetic hand since patients need complex hand movements to manipulate objects. But, it is not easy to design prosthetic hand because of large number of muscles and joints enabling a high degree of freedom.

Acquisition of Electromyographic (EMG) signals and classification of patterns, the first two steps in building successful prosthetic hand controlled by complex tags from the processor running classification algorithms, are emphasized in this thesis. Surface EMG signals of forearm flexor and extensor muscles of voluntary participants, emerged as a result of 7 basic hand movements are acquired by active electrodes, amplified, digitized and then transferred to a computer for processing. EMG signals are filtered first and then pre-processed before time and time-frequency domain features are extracted. Combinations of time and time-frequency domain features are then used to train an artificial neural network (ANN) to perform classification. Correct classification ratios for both data from the training set and test set which the ANN is not trained for are reported besides significant findings.

**Key Words:** EMG Signals, Myoelectric Control Systems, Electromyography, EMG features, Artificial Limbs, Artificial Neural Networks.

## ŞEKİLLER DİZİNİ

### Sayfa No

Şekil 1. Motor ünitenin yapısı (Dr. Carlo J. De Luca'nın izniyle yeniden düzenlenmiştir.) [14].	5
Şekil 2. Motor üniteleri aksiyon potansiyelleri ve EMG sinyali oluşumu (Dr. Carlo J. De Luca'nın izniyle tekrar düzenlenmiştir) [14].	5
Şekil 3. EMG sinyali frekans aralığı	6
Şekil 4. EMG sinyalleri elde etmede kullanılan iğne elektrotları [17].	7
Şekil 5. Hedef kas sinirinin yeniden bağlanması [21].	9
Şekil 6. Tek kanallı EMG yükselteç devresi	10
Şekil 7. Ana dalgacıklara göre ortalama kareler hatası	16
Şekil 8. Geçici ve kalıcı durum EMG sinyalleri	19
Şekil 9. Bitişik (adjacent) pencereleme	19
Şekil 10. Örtüşmeli (overlapped) pencereleme	20
Şekil 11. Bir pencereye ait hesaplanan ortalama mutlak değer	21
Şekil 12. Bir pencereye ait $I=5$ için hesaplanan OMDE değerleri	22
Şekil 13. Bir pencereye ait eşik değeri 0,3 olan SGTS yerleri	23
Şekil 14. 4 pencereden oluşan 600 ms'lik bir sinyal	24
Şekil 15. Dalga boyu özneliği değerlerinin gösterimi	25
Şekil 16. 6 tekrarlı bilek bükme hareket sınıfına ait EMG kaydı	26
Şekil 17. AR katsayıları	26
Şekil 18. Dalgacık dönüşümü zaman ölçek gösterimi [41].	29
Şekil 19. Ana dalgacık fonksiyonunun farklı ölçek parametrelerinde Güç spektrumu [41].	30
Şekil 20. EMG sinyalinin ADD ile alt bileşenlere ayrıştırılması	32
Şekil 21. Yapay sinir ağı örneği	35
Şekil 22. Yapay sinir hücresinin (nöron) yapısı	36
Şekil 23. Bazı aktivasyon(transfer) fonksiyonları	37
Şekil 24. İleri beslemeli ve geri beslemeli yapay sinir ağları	39
Şekil 25. Hatanın geri yayılması	42
Şekil 26. Yapılan çalışmaların temel işlem adımları	44
Şekil 27. EMG sinyallerinin alındığı ekstensör kas grubu	47
Şekil 28. EMG sinyallerinin alındığı fleksör kas grubu	48

Şekil 29. Deri yüzeyine elektrotları sabitleyen yapışkanlı etiket.....	49
Şekil 30. Serbest hareket sınıfına ait oturum kaydı.....	49
Şekil 31. Bilek bükme hareket sınıfına ait oturum kaydı.....	51
Şekil 32. Oturum kayıtlarının bilgisayar ortamına aktarılması .....	54
Şekil 33. Dosya isimlendirmeleri için kullanılan protokol .....	54
Şekil 34. EMG sinyallerinin sayısal filtrelerden geçirilmesi .....	55
Şekil 35. Kalıcı durum EMG sinyallerinin seçilmesi.....	56
Şekil 36. Kullanılan öznitelik grupları .....	57
Şekil 37. Özniteliklerin çıkartılması .....	58
Şekil 38. SGTS özniteliğine ait 0,1 – 0,6 aralığı eşik değerlerinde saçılım grafiği .....	60
Şekil 39. SGTS özniteliğine ait 0,9 – 2,4 aralığı eşik değerlerinde saçılım grafiği .....	60
Şekil 40. SGTS özniteliği çeşitli eşik değerlerinde sınıflandırma sonuçları.....	61
Şekil 41. WG özniteliğine ait 0,1–0,6 aralığı eşik değerlerinde saçılım grafiği .....	61
Şekil 42. WG özniteliğine ait 0.1 – 6.6 aralığı eşik değerlerinde saçılım grafiği .....	62
Şekil 43. WG özniteliği çeşitli eşik değerlerinde sınıflandırma sonuçları.....	62
Şekil 44. EGD özniteliğine ait 0,1-0,5 aralığı eşik değerlerinde saçılım grafiği .....	63
Şekil 45. EGD özniteliğine ait 0,7-1,2 aralığı eşik değerlerinde saçılım grafiği .....	63
Şekil 46. EGD özniteliği çeşitli eşik değerlerinde sınıflandırma sonuçları .....	64
Şekil 47. Yapay sinir ağının topolojik yapısı .....	66
Şekil 48. Sınıflandırma için ağa sunulacak olan matrisin öznitelik yerleşimi. ....	67
Şekil 49. 1-10. derecelerden AR modelleri katsayıları sınıflandırma sonuçları .....	69
Şekil 50. AR katsayılarının farklı ZD öznitelikleriyle ayrı ayrı birleşimi sonuçları.....	70

## TABLolar DİZİNİ

### Sayfa No

Tablo 1. Bazı yüzey elektrot çeşitleri .....	8
Tablo 2. Bit çözünürlüğü, referans gerilimi ve çözünürlük değeri arasındaki ilişki .....	12
Tablo 3. Ana dalgacık fonksiyonları .....	15
Tablo 4. Dalgacık dönüşümü gürültü giderme için seçilebilecek parametreler .....	18
Tablo 5. Kullanılan aktif elektrotların teknik özellikleri.....	45
Tablo 6. Ana yükselteç ünitesi teknik özellikleri .....	46
Tablo 7. Analog sayısal dönüştürücü kartı özellikleri.....	46
Tablo 8. Katılımcılara ait bazı bilgiler .....	48
Tablo 9. Serbest sınıfı ve oturumlarda uygulanan protokol .....	50
Tablo 10. Altı hareket sınıfı ve bu sınıfların oturumlarında uygulanan protokol .....	50
Tablo 11. Oturumlar arası uygulanan protokol (1.aşama).....	52
Tablo 12. Oturumlar arası uygulanan protokol (2.aşama).....	52
Tablo 13. Her bir sınıfa ait toplam süreler ve toplam tekrar sayısı .....	53
Tablo 14. Bazı öznitelikler için bulunan en iyi eşik değerleri.....	64
Tablo 15. Hareket sınıflarının ikili olarak kodlanması.....	65
Tablo 16. ZD özniteliklerinin farklı pencere boylarında sınıflandırma sonuçları.....	71
Tablo 17. ZD+AR2 özniteliklerinin farklı pencere boylarında sınıflandırma sonuçları.....	72
Tablo 18. ZD+AR4 özniteliklerinin farklı pencere boylarında sınıflandırma sonuçları.....	72
Tablo 19. Dalgacık katsayıları öznitelikleriyle elde edilen sınıflandırma sonuçları.....	73
Tablo 20. Öznitelik gruplarının birleştirilmesiyle elde edilen sınıflandırma sonuçları .....	74
Tablo 21. Benzer çalışmalarda diğer sınıflayıcılar kullanılarak elde edilen sonuçlar.....	75
Tablo 22. Literatürdeki Yapay Sinir Ağları sınıflayıcısı ile alınan benzer sonuçlar.....	76

## SEMBOLLER DİZİNİ

EMG	Elektromiyografi
MES	Miyoelektrik Sinyal
AP	Aksiyon Potansiyeli
Hz	Hertz
Ag	Gümüş
AgCl	Gümüş Klorür
TMR	Targeted Muscle Reinnervation
CMRR	Ortak Modu Bastırma Oranı
dB	Desibel
SENIAM	Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles
ISEK	International Society of Electrophysiology and Kinesiology
ADC	Analog Digital Converter
$\mu$ V	mikroVolt.
RMS	Root Mean Square
V	Volt
mV	miliVolt
ADD	Ayrık Dalgacık Dönüşümü
MSE	Mean-Square Error
DD	Dalgacık Dönüşümü
SDD	Sürekli Dalgacık Dönüşümü
ms	milisaniye
ZD	Zaman Düzlemi
ZFD	Zaman-Frekans Düzlemi
OMD	Ortalama Mutlak Değer
OMDE	Ortalama Mutlak Değer Eğimi
SGTS	Sıfır Geçiş Tespit Sayısı
DB	Dalga Boyu
AR	Özbağlanım Katsayıları
KZFD	Kısa Zaman Fourier Dönüşümü
ADPD	Ayrık Dalgacık Paket Dönüşümü
cA	Yaklaşım Katsayıları

cD	Detay Katsayıları
YSA	Yapay Sinir Ağları
mm	milimetre
cm	santimetre
mW	miliWatt
kS/s	1 saniyede yapılan 1000 örnekleme sayısı
USB	Universal Serial Bus

## 1. GENEL BİLGİLER

### 1.1. Giriş ve Çalışmanın Amacı

Son yüzyıldaki bilim ve teknolojiye yapılan çalışmalar, insan vücudunu daha iyi tanıyabilmek için yeni yöntem ve teknikler sunarak bu konuda ciddi ilerlemeler sağlamaktadır. Özellikle vücudumuzun üretmiş olduğu elektriksel işaretler vücudumuzdaki sistemlerin çalışmasıyla ilgili önemli bilgiler içerir. Bu elektriksel işaretlerden biride kas hücrelerimizin kasılıp gevşemesiyle ortaya çıkan ve miyoelektrik olarak adlandırılan işaretlerdir. Miyoelektrik işaretlerin insan vücudundan elde edilip kaydedilmesi ve analiziyle ilgili yöntemlerin bütününe ise elektromiyografi denir [1].

Günümüzde EMG sinyallerinin farklı kullanım alanları vardır. Yaygın olarak kullanıldığı alanlara; sinir (nöron)-kas hastalıklarının (nöromüsküler) ve kas hastalıklarının (miyopati) teşhisi, gırtlak (laringeal veya larinks) EMG'si olarak adlandırılan ses tellerini çalıştıran kaslarla ilgili bazı rahatsızlıkların teşhisi, konuşma tanımaya yardımcı uygulamalarda, spor bilimleri ve aktif el-kol protezlerin kontrolünde kullanılması örnek olarak verilebilir. Aktif el ve kol protezler kişinin isteğiyle beyinden kaslara iletilen EMG sinyallerinin gerçek zamanlı (azami 300 milisaniye gecikmeli) işlenmesi sonucu kontrol edilen protezlerdir. Bu şekilde miyoelektrik sinyaller (MES) ile tek bir protez uzvun(el-kol) isteğe bağlı kontrolünü sağlayan sistemlere miyoelektrik kontrol sistemleri denir.

MES ile ilgili dikkat çeken ilk çalışmalar 1950'li yılların sonunda yapılmış, 1960'larda ise el-kol protezlerinde kullanılmaya başlanmıştır [2,3,4]. İlk miyoelektrik kontrol sistemi, kol kaslarından alınan EMG sinyalinin genlik değeri önceden belirlenmiş bir eşik seviyesi ile karşılaştırılarak kullanıcının yapmak istediği el açma/kapama gibi hareketlerin kontrolünü sağlamış ve bu sistem doğrudan kontrollü aktif protez olarak adlandırılmıştır [5,6]. Benzer şekilde EMG sinyalinin genlik özelliği kullanılarak kasların kasılma yoğunluğuna göre protezin istenen harekete ait hızı kontrol edilmiş, bu ise doğrudan oransal kontrollü aktif protez olarak adlandırılmıştır [5,6]. Bu iki yöntem pratik uygulamalarda oldukça kabul görmüştür [5,6]. Fakat bu sistemlerin tek serbestlik dereceli olmasından dolayı sınırlı sayıda hareket sınıfının (el açma/kapama) kontrolü sağlanabilmiş, daha fazla hareket sınıfının kontrolünün sağlanabilmesi ise aşılması gereken en önemli



problem olmuştur. Bu nedenle doğrudan kontrol sisteminin çalışmasını temel alan, genliği çok durumlu miyoelektrik kontrol sistemi olarak adlandırılan farklı bir yöntem ile EMG sinyali genlik özelliği dinamik aralıklı seviyelere bölünmüş, her bir seviye ise farklı hareket sınıfına eşleştirilerek kontrol edilen hareket sınıfı sayısı artırılmıştır [5,6]. Genliği çoklu durumlu miyoelektrik kontrol sistemi ile çalışan aktif protezlerin kullanıcılarda oluşturduğu bilişsel yükten (yoğun odaklanma gerekliliği) dolayı bu protezlerin kullanımı zor olmuştur [5,6]. Bu sistemlere benzer EMG sinyaline ait genlik özelliğini kullanarak oluşturulan ve mod anahtarlı (kasılma anının ateşlenmesi veya donanımsal bir anahtar ile hareketler arası geçiş) kontrol olarak adlandırılan sistemler de yapılmıştır [5,6,7].

EMG sinyalinin genlik özelliğini kullanan miyoelektrik kontrol sistemlerinin tümü klinik uygulamalarda iyi sonuç vermelerine ve kolay uygulanabilir olmalarına karşın kontrol edilmek istenen her bir duruma ait bağımsız kasların kullanılması gerektiğinden çok fonksiyonlu (birden fazla serbestlik derecesi olan) kontrollerde yetersiz kalmıştır [7,8]. Literatürde bu sistemler geleneksel miyoelektrik kontrol sistemler olarak adlandırılmıştır. 1970'lerden itibaren yarı iletken teknolojisindeki ilerlemeler, mikroişlemcilerin hızlanması ve maliyetlerinin düşmesi kullanım alanlarını genişletmiştir. Miyoelektrik kontrol sistemlerinde mikroişlemcilerin kullanılması gelişmiş sinyal işleme yöntemlerini uygulama, yapay zeka tekniklerini kullanabilme, sinyal üzerinde daha duyarlı karmaşık filtreleme yapabilme ve daha da önemlisi kontrol edilen işlevlerin çeşitliliğini artıran örüntü tanıma tabanlı yeni bir miyoelektrik kontrol sistemine olanak sağlamıştır. Örüntü tanıma tabanlı miyoelektrik kontrol sistemleri elektrotların belirli bir konumda tekrarlanabilir belirli kas grubu hareketlerinin örüntülerini tanımlayan özniteliklerin varsayımına dayanır [9]. Bu sistemler geleneksel miyoelektrik kontrol sistemlere göre daha fazla serbestlik derecesini (el açma/kapama ve bileğin döndürülebilmesi) kontrol edebilir. Çünkü işaretin alındığı kas bölgesi ve serbestlik derecesi arasında bire bir eşleme yapmaya gerek duymaz [9].

Günümüzde ticari amaçlı üretilen aktif el ve kol protezleri az sayıda serbestlik derecesi içererek normal elimizin veya kolumuzun kabiliyetine göre oldukça ilkeldirler [10]. Aslında bu durum iskelet kaslarımızı harekete geçiren motor sinirlerinin bulunduğu somatik sinir sistemi içinde birde duyuşal sinirlerimizin (reseptörler) varlığıyla

açıklanabilir. Bu sınırlar dokunma, sıcaklık, konum algısı, ağrı ve acı gibi hisleri deri yüzeyinden algılayarak bizlere geribildirim sağlarlar [10]. Ticari olan aktif el ve kol protezlerin hiç birinde duyuşal geri bildirim yapabilen bir geri bildirim sistemi yoktur [10]. Ancak titreşim ve mekanik gürültü gibi geri bildirim sağlayan sistemler vardır [10].

EMG sinyallerinin aktif protezlerde kullanılmasıyla ilgili yapılan çalışmalar temelde iki gruba ayrılabilir. Araştırmacıların bir bölümü, örüntü tanıma tabanlı yaklaşımın klinik uygulamalarda (el veya kol kaybı olan gönüllü kişiler üzerinde denenmesi) yer alabilmesi için yeni yöntemlerin geliştirilmesi üzerinde çalışmaktadırlar. Diğer bir bölüm araştırmacılar ise örüntü tanıma tabanlı yaklaşımın ticari sistemlerde henüz uygulanabilir olamamasından dolayı geleneksel kontrol yaklaşımını temel alan, daha fazla serbestlik derecesini kontrol edebilen ve bunların klinik uygulanabilirliğini artırmak için yeni yöntemlerin geliştirilmesi üzerinde çalışmaktadırlar. Geleneksel kontrol yaklaşımlı yöntemlere son yıllardaki ticari uygulamalarda da kullanılan paylaşımlı kontrol yöntemi [7,9] ve duyuşal geri bildirimli kontrol yöntemleri örnek olarak verilebilir [8,9]. Paylaşımlı kontrol yöntemi ile çalışan protezlere örnek olarak Otto Bock firmasının SensorHand Speed protezi ve Touch Bionic firmasının iLIMB protezi gösterilebilir [10]. SensorHand Speed elin kavrama gereksinimini otomatik olarak algılar ve tutulan nesnenin kaymasını önler [10]. Aynı şekilde iLIMB ise bir nesneyi verimli bir şekilde kavramasını sağlayan kadar otomatik olarak bir kavrama metodunu gerçekleştirir [10]. Burada protezin kontrolü sadece kullanıcının kontrolünde değildir. Paylaşımlı kontrol olarak adlandırılması da bu sebeptendir. Kullanıcı istemiş olduđu hareketi başlatır sonrası ise protez tarafından otomatik olarak gerçekleştirilir [10]. Yapılmak istenen hareketin gerçekleştirilebilmesi kadar duyuşal geribildirim sağlanabilmesi aktif bir protezin kontrolü için oldukça önemlidir. Kullanıcının sadece görsel geribildirimiyle kontrol edilen bir protez hem yanlış işlevlerin yapılmasına hem de hantal çalışmasına sebep olacaktır [10]. Geleneksel kontrol yaklaşımı temelli bu yöntemlerin serbestlik derecesi ve bağımsız kas sayısı sınırlamasından dolayı araştırmacıların diğer bir bölümü örüntü tanıma tabanlı kontrol yaklaşımı üzerinde çalışmaktadırlar. Örüntü tanıma tabanlı kontrol yaklaşımında araştırmacılar, çoklu serbestlik derecelerinin protez üzerinde eş zamanlı ve oransal kontrolünü sağlayabilmek (bileğimizin dönme hareketiyle aynı anda elimizin oransal açılması gibi), az sayıda kanal


kullanılarak daha fazla serbestlik derecesini kontrol edebilmek ve gerçek uygulamalarda daha fazla yer almasını sağlamaya çalışmaktadırlar [7,11,12].

Bu çalışmanın amacı örüntü tanıma tabanlı kontrol sistemi yaklaşımının klinik uygulamalarda kullanılabilirliğine katkı sağlamaktır. Bu sebeple EMG sinyalleri 2 kanaldan alınarak 7 farklı el ve kol hareketinin iyi oranda yapay sinir ağları ile sınıflandırılması hedeflenmiştir. EMG sinyallerine ait zaman ve zaman-frekans düzlemi özniteliklerinin ayrı ayrı ve farklı birleşimlerinin sınıflandırmadaki performansı yapay sinir ağlarıyla değerlendirilecektir. İlk bölümde EMG sinyallerinin elde edilmesi, ön işleme aşamaları, özniteliklerinin çıkartılması ve sınıflandırılmasıyla ilgili genel bilgiler verilecektir. İkinci bölümde ise yine bu adımlara göre yapılan çalışmalardan ve bulgulardan bahsedilecek. Son bölümde yapılan çalışmaların sonuçları değerlendirilecek, gelecekte yapılacak çalışmalar için önerilerde bulunulacaktır.

## **1.2. EMG İşaretlerinin Oluşumu ve Özellikleri**

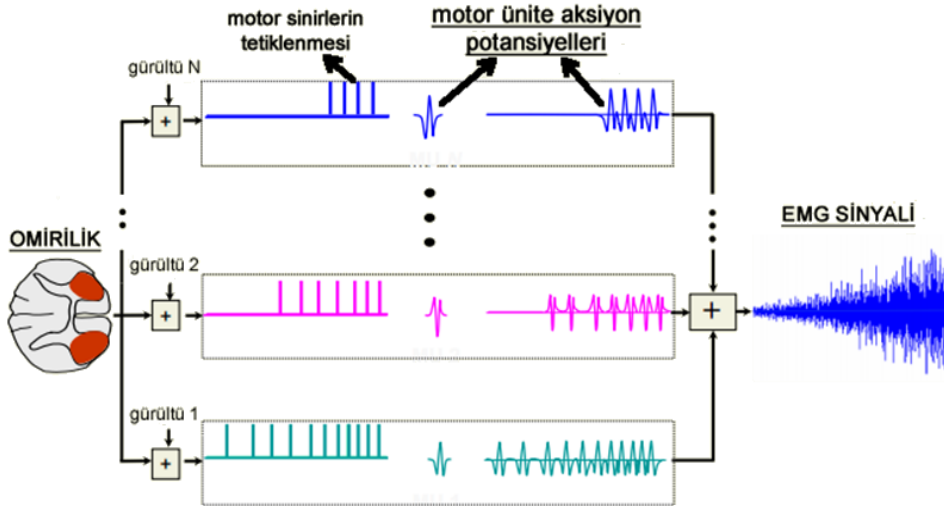
Vücudumuzun en temel birimi olan hücrelerimizin içinde ve dışında bir iyon dengesi vardır. İstemli bir hareket gerçekleştirmek istediğimizde beyin (motor korteks bölgesinde) uyarılabilme özelliğine sahip sinir (nöron) hücrelerimizin iyon dengesini değiştirmesi sonucu hücrelerde elektriksel bir potansiyel oluşturur. Bu potansiyele aksiyon potansiyeli (AP) denir. AP oluşan bir sinir hücresi kendisine bağlı sinir hücrelerinin de iyon dengesini değiştirerek bu sinir hücrelerinde de AP oluşturur. Birbirine bağlı sinir hücrelerinin bu şekilde tetiklenmesiyle uyarı, omurilik üzerinden hedef kas bölgesine kadar iletilmiş olur. Burada uyarının taşınmasını motor sinirler gerçekleştirir. Bir motor sinirinin son ucu, bir kası oluşturan binlerce kas lifinden değişken sayıda bağlanarak bu liflerin kasılma ve gevşemesini sağlar [13].

Motor sinirin son plak ile kas liflerine bağlandığı yapıya motor ünite denir [13]. Şekil 1’de bir kasa bağlı farklı motor ünitelerin yapısı görülmektedir. Bir kasın çalışmasında farklı sayıda motor ünite görev alır. Motor ünitelerin sayısı kasın görevine göre değişiklik gösterir. Şekil 2’ de bir kasın kasılmasının başlaması ve devam etmesi için kasa bağlı motor ünitelerin oluşturdukları aksiyon potansiyelleri ve bu potansiyellerin toplamından ham EMG sinyalinin oluşumu gösterilmiştir.



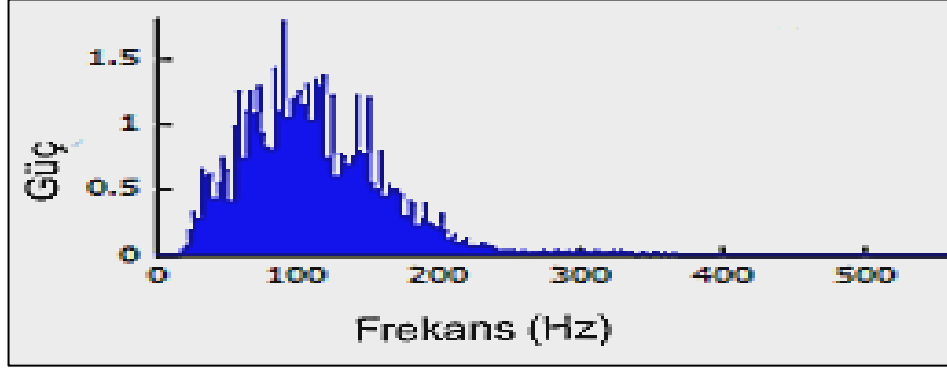
Şekil 1. Motor ünitenin yapısı  
(Dr. Carlo J. De Luca'nın izniyle yeniden düzenlenmiştir.) [14].

EMG sinyallerinin elektriksel özelliklerini inceleyecek olursak genliği mikro voltlar düzeyinde olup değeri, alınan kişinin yaşına, cinsiyetine ve alındığı kasın türüne göre değişiklik gösterebilir.



Şekil 2. Motor üniteleri aksiyon potansiyelleri ve EMG sinyali oluşumu  
(Dr. Carlo J. De Luca'nın izniyle tekrar düzenlenmiştir) [14].

EMG durağan olmayan bir yapıda olduğu için belirli bir frekans değeri yoktur. Şekil 3'te görülüşü gibi frekans bandı 10-500 Hertz (Hz) arasında olup, baskın frekans değeri 30-150 Hz dolaylarındadır.



Şekil 3. EMG sinyali frekans aralığı

### 1.3. EMG Sinyallerinin Elde Edilmesinde Kullanılan Yöntemler

EMG sinyallerinin kullanım amacına göre elde edilme yöntemleri farklılıklar göstermektedir. İğne elektrotlar ile kas içinden elde edileceği gibi aktif veya pasif elektrotlar ile kas grubunun bulunduğu deri yüzeyinden de elde edilebilir. Ayrıca kolunun tamamını kaybetmiş kişilere uygulanacak aktif protezlerde EMG sinyalinin elde edileceği kas bölgesi olmadığı için cerrahi işlemler sonucu motor sinirlerin taşınarak EMG sinyalini farklı kas bölgelerinden elde etme gibi yeni yöntemlerde vardır.

Yüzey EMG sinyallerinin elde edilmesinden işlenip çeşitli alanlarda kullanılmasına kadar uygulanan yöntem, araç ve teknikler araştırma grupları arasında farklılıklar göstermektedir. Bu farklılıkları bir standarda kavuşturmak için, Avrupa Birliği Biyomedikal Sağlık ve Araştırma Programı (BIOMED II) çerçevesinde yürütülmekte olan Girişimsel Olmayan Kas Değerlendirmeleri için Yüzey Elektromiyografisi (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles - SENIAM) Projesi başlatılmıştır. Benzer şekilde Uluslararası Elektrofizyoloji ve Kinesiyoloji Derneği (International Society of Electrophysiology and Kinesiology- ISEK) de insan hareketini ve sinir-kas sistemini incelemek üzere insan sağlığı ve temel bilimlerle ilgili çalışmalar yapan araştırmacıların ortak bir arzu ile oluşturduğu çok disiplinli bir organizasyondur. Bu iki topluluğun EMG standartlarıyla ilgili çeşitli rapor ve yayınları vardır. SENIAM ve ISEK topluluklarının belirlemiş oldukları standartlarda temelde farklılıklar olmayıp, EMG sinyallerinin temizlenmesi için uygulanacak olan filtrenin bant genişliği değerinin belirlenmesi gibi standartların bazılarında ise küçük farklılıklar da yer almaktadır.

### 1.3.1. İğne Elektrot Kullanarak EMG Sinyalinin Elde Edilmesi

Genellikle kas ve sinir hastalıklarının teşhisi için hekimin iğne elektrotu kas içine yerleştirip ölçümün yapılmasıyla gerçekleşen girişimsel (invaziv) bir yöntemdir. Burada amaç bir motor ünitenin aktivitelerini yakından inceleyebilmek ve doğru tanıyı koyabilmektir. Bu sebeple kasa ait daha yerel bilgilerin elde edilmesini sağlar. Ölçüm yapılacak kas bölgesinin dışında yüzeye yapıştırılan referans elektrot ile birlikte yükseltme yapılacak birime elde edilen işaretler aktarılır. İğne elektrotların bazıları doğrudan genlik ölçümü yaparken bazıları ise dışarıdan uygulanan bir uyarıya verilen tepki süresini belirler. Kullanıma göre çeşitleri vardır. Bunlar; tek fiber, tek kutuplu, çok kutuplu, eş merkezli (konsantrik) ve makro elektrotlardır. Bunlardan bazıları tek kullanımlık bazıları ise dezenfekte edilerek birden fazla kullanılabilir elektrotlardır. Bazı iğne elektrotlar Şekil 4’de gösterilmiştir. Son yıllarda aktif protezlerin çoklu serbestlik dereceleri yerine getirebilmek için iğne elektrotlar ile kas içinden elde edilen EMG sinyallerinin de kullanılmasıyla ilgili çalışmalar yapılmaktadır [15,16].



Şekil 4. EMG sinyalleri elde etmede kullanılan iğne elektrotları [17].

### 1.3.2. Yüzey Elektrot Kullanarak EMG Sinyalinin Elde Edilmesi

Yüzey elektrotlar EMG sinyalinin elde edileceği kas bölgesinin deri yüzeyine aktif veya pasif elektrotların yerleştirilip ölçümün başlamasıyla gerçekleşen girişimsel olmayan (non invaziv) bir yöntemdir. Aktif yüzey elektrotlar üzerlerinde bulunan bir yükselteç devresiyle ölçüm yapılan bölgede işareti belirli bir kat yükseltirler. Pasif elektrotlarda ise üzerlerinde herhangi bir devre olmayıp, işaret elde edilir edilmez yükseltme yapılmaz. İğne

elektrotlarıyla EMG sinyallerinin elde edilmesinde olduğu gibi bu elektrotlar ile birlikte ölçüm yapılan bölgeden farklı bir yere referans elektrot yapıştırılmalıdır. İğne elektrotları kullanılan kas içi ölçümlere göre, kasın tüm motor ünitelerinden gelen bilgiler elde edildiği için daha genel bilgilerin elde edilmesini sağlar. EMG sinyalleri kullanılan aktif el-kol protezlerinin kontrolünde yüzey elektrotlar kullanılır. Bu elektrotların deri yüzeyi ile temas edeceği bölgede ya saf gümüş (Ag) ya da gümüş klorürden (AgCl) yapılmış iletkenliği yüksek malzeme kullanılır. Bazı yüzey elektrot çeşitleri Tablo 1’de gösterilmiştir

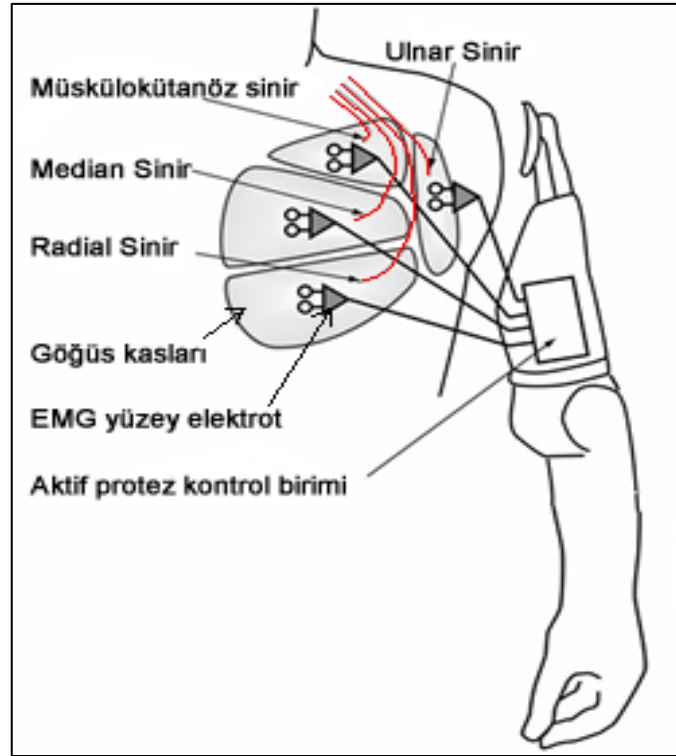
Tablo 1. Bazı yüzey elektrot çeşitleri

Yüzey Elektrot Türü	Örnek Görünüm	Açıklama
Pasif yüzey elektrotu		Tek kullanımlık ve önceden jelli yüzey elektrot [18].
Aktif yüzey elektrotu		Birden fazla kullanılabilir aktif elektrot [19].
Referans elektrotu		İletken yapışkanlı elektrot [20].

### 1.3.3. Hedef Kas Sinirinin Yeniden Bağlanması Yöntemi

TMR (Targeted Muscle Reinnervation) yöntemi kolunun tamamını kaybetmiş kişilere aktif protez geliştirebilmek için ilk defa Chicago Rehabilitasyon Enstitüsünden Dr. Todd Kuiken ve arkadaşları tarafından cerrahi bir operasyonla gerçekleştirilmiştir [6]. Bu

yöntemde hedef kaslara (kol kasları) bağlı motor sinirlerin cerrahi bir operasyonla göğüs kaslarına yeniden bağlanması ve göğüs kasları üzerinden protezi kullanan kişinin yapmak istediği hareketle ilgili AP'nin yüzey elektrotlar ile elde edilmesi ve işlenmesiyle gerçekleşir. Ulnar, Median, Radial ve Müskülokütanöz kolumuza ait sinirlerdir. Şekil 5'te de gösterildiği gibi bu sinirler (kırmızı renkli gösterim) göğüs bölgesindeki kaslara tekrar bağlanmıştır. Aktif protezi kullanan kişi, istemli el-kol hareketi yapmak istediğinde göğüs bölgesinde oluşan AP'lerin elde edilmesiyle oluşan yüzey EMG sinyalleri kontrol amaçlı kullanılır.



Şekil 5. Hedef kas sinirinin yeniden bağlanması [21].

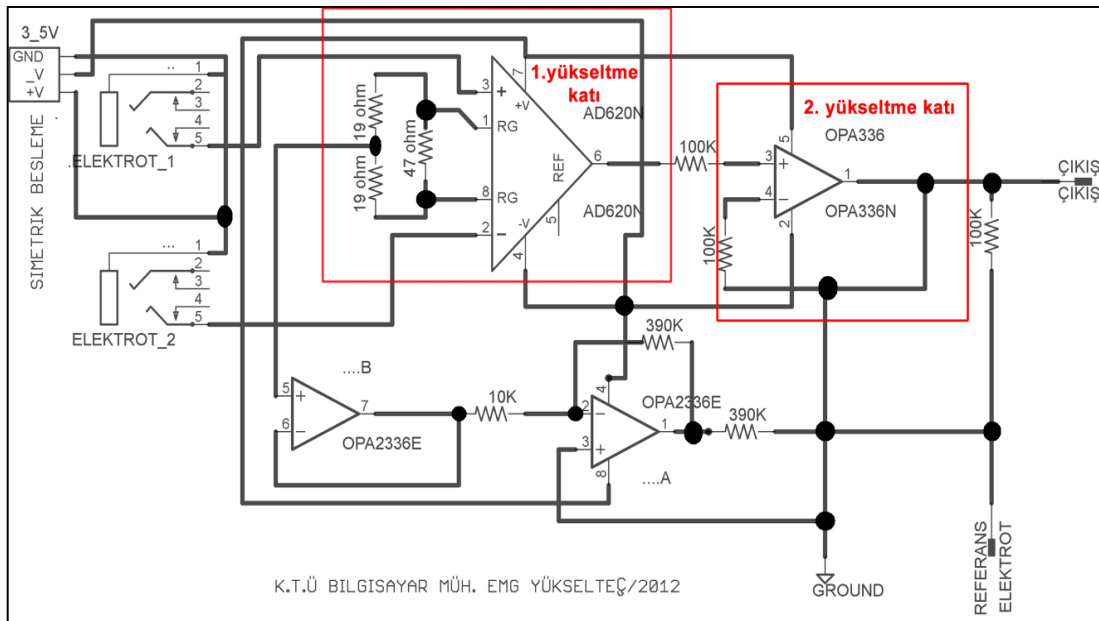
#### 1.4. EMG Sinyallerinin Elde Edilmesi ve Kaydedilmesi

##### 1.4.1. Sinyalin Yükseltilmesi

EMG sinyalleriyle ilgili hem örüntü tanıma tabanlı hem de geleneksel yöntemle yapılan çalışmalarda elde edilen EMG sinyalleri mikro voltlar düzeyinde olduğundan bu



sinyallerin izlenmesi ve işlenebilmesi için yükseltilip sayısallaştırılması gerekmektedir. Şekil 6’da bu tez çalışmasının başlangıç aşamasında EMG sinyallerinin elde edilip özelliklerinin bir osiloskop yardımıyla izlenebilmesi için Karadeniz Teknik Üniversitesi Sayısal İşaret İşleme (Digital Signal Processing) Laboratuvarında gerçekleştirilen tek kanallı EMG yükselteç devresi gösterilmektedir. Bu devrede yüzey elektrotlar ile deri yüzeyinden alınan EMG sinyalleri ilk olarak enstrümantasyon yükselteci ile yaklaşık 1000 kat yükseltilir, çıkışı işlemsel yükseltece aktarılarak 2 kat daha yükseltme işlemi yapılır ve sinyal son çıkışa verilir. Bu devre pasif iki yüzey elektrot kullanılarak test edilmiştir. Şekil 6’daki ilk yükseltme katında bulunan enstrümantasyon yükseltecine ölçüm yapılan bölgeden mutlaka referans bir değer girişi olmalıdır. Bu sebeple üçüncü bir yüzey elektrotu kullanılmalı ve bu elektrot ölçümün yapıldığı kas bölgesinden farklı bir yere yerleştirilmelidir. Örneğin ön kol da ölçüm yapılacaksa referans elektrot, ya dirsek bölgesine ya da el bileği bölgesinde kas içermeyen bir yere yerleştirilebilir.



Şekil 6. Tek kanallı EMG yükselteç devresi

Biyoelektriksel sinyalleri elde etmek için tasarlanan elektronik devrelerdeki en önemli elamanlar yükselteçlerdir. Bu devrelerde yükseltme işleminde fark yükselteci (enstrümantasyon yükselteci bir fark yükseltecidir) kullanılır. Fark yükselteçlerinin

performansını gösteren en önemli özelliklerinden biri ise ortak modu bastırma oranıdır (CMRR-Common Mode Rejection Ratio). Birimi desibel (dB) olan CMRR değeri ne kadar yüksek olursa fark yükseltici sinyale karışan gürültü bileşenlerini o kadar iyi bastıracaktır. SENIAM ve ISEK, EMG sinyallerinin elde edilmesinde kullanılan fark yükselteçlerin CMRR değerinin 95 dB'den büyük olmasını kabul edilebilir bir değer saymışlardır [1]. Şekil 6'daki devrede kullanılan AD620N (Analog Devices Inc.) enstrümantasyon yükseltecinin üretici veri sayfasında CMRR değeri, kazancın 1000 kat ayarlandığı durumda minimum 110 dB olarak verilmiştir [22]. Şekil 6'da gösterilen devrede sinyal çıkışı izlenirken herhangi bir filtre uygulanmamıştır. EMG sinyalleri elde edilirken sinyale birçok gürültü bileşeni karışır. Bu gürültü bileşenlerini; şebeke geriliminden kaynaklı, devre elemanlarından kaynaklı, ölçüm anında yüzey elektrotlarının veya bağlı kabloların hareketlerinden kaynaklı, nabız veya kalbe yakın yerlerde bulunan kaslardan veri elde edilirken (TMR de olduğu gibi) kalp kaslarının oluşturduğu elektriksel potansiyellerden (Elektrokardiyogram) kaynaklı ve ölçümün yapıldığı ortamdaki manyetik alan kaynaklı gürültüler olarak sıralayabiliriz. Birçok gürültü bileşeni olması sebebiyle 1. yükseltme katı sonuna (30 Hz ve üzerini geçiren) ve devrenin son çıkışına (500 Hz ve altını geçiren) mutlaka filtre uygulanmalıdır. Örnek bir 4 kanallı EMG yükselteç devresi [23]' de gerekli filtreler de kullanılarak gerçekleştirilmiştir.

#### **1.4.2. Sinyalin Sayısallaştırılması**

Yükseltilmiş ve belirli filtrelerden geçirilmiş EMG sinyallerinin dijital ortama aktarılıp kaydedilmesi veya gerçek zamanlı işlenebilmesi için sayısallaştırılması gerekmektedir. EMG gibi analog sinyallerin sayısallaştırılabilmesi analog/dijital dönüştürücü devrelerle (ADC) gerçekleştirilir. Bu dönüşümde önemli olan 2 parametre vardır. Bunlardan ilki örnekleme frekansıdır. Örnekleme frekansı sayısal dönüşümden sonra sinyalin tekrar elde edilebilmesi için gereklidir ve analog sinyalden 1 saniye de kaç örnek alınacağını belirtir. Dönüşüm işleminde kullanılacak örnekleme frekansını belirlerken Nyquist Örnekleme Teoremi kullanılır. Bu teoreme göre; örnekleme frekansı analog sinyalin en yüksek frekansının en az iki katı olmalıdır. Yüzey EMG sinyallerin en yüksek frekansı yaklaşık 500 Hz'dir. Bu sebeple ADC' işleminde seçilecek örnekleme

frekansı minimum 1000 Hz olarak belirlenmelidir. Daha yüksek seçilmesi durumunda ise hesaplama yükü oluşur.

Tablo 2. Bit çözünürlüğü, referans gerilimi ve çözünürlük değeri arasındaki ilişki

Bit Çözünürlüğü (n)	Seviye $N=2^n-1$	V/Seviye= $10/N$ ( $\pm 5V$ Referans Gerilimi)	Çözünürlük Değeri (Yükselteç kazancı=1000 ve $\pm 5V$ Referans gerilimi)
8	255	39.06mV	39.06 $\mu V$
10	1023	9.765mV	9.765 $\mu V$
12	4095	2.441mV	2.441 $\mu V$
14	16383	0.610mV	0.610 $\mu V$
16	65535	0.152mV	0.152 $\mu V$

ADC işlemlerinde ikinci önemli parametre ise bit çözünürlüğüdür. Bit çözünürlüğü belirli zaman aralıklarında alınan örneklemelerin kaç bit ile temsil edileceğini belirtir. ADC entegresinin çözünürlük değeri, en düşük öncelikli bit değerinin 1, diğerlerinin 0 olduğu durumda ki çıkış gerilimine eşittir. Örneğin 10 bit çözünürlükte olan bir ADC' nin referans gerilimi +5V (volt) verilmiş olsun. +5V değeri  $2^n-1$  (n=bit sayısı)  $2^{10}-1 = 1023$ 'e bölündüğünde 4.88 mV (mili volt) çözünürlük değeri olarak hesaplanır. ADC, analog sinyalden örneklem aldığı her bir değeri, 4.88 mV'luk değer aralıklarından oluşan 1023 seviye ile karşılaştıracak ve karşılaştırma sonunda elde ettiği en yakın değer, örneklem alınan analog sinyal değerinin sayısal değeri olarak çevrilmiş olacaktır (Kuantalama-Kodlama işlemi). ADC çeviricilerde bit sayısı arttıkça daha hassas çevrim gerçekleşmiş olmakla birlikte çeviricinin maliyeti de artacaktır. EMG sinyallerinin sayısallaştırma işlemlerinden önce sinyali yükseltme işleminde uygulanan toplam yükseltme katsayısı ve ADC'nin giriş referans değeri (volt) birbirinden bağımsız belirlenecek parametreler değildir [24]. Bu değerler gürültü seviyesi dikkate alınarak istenen çözünürlük değerine bağlıdır [24]. Örneğin  $\pm 5V$  referans girişli bir ADC'nin tepeden tepeye değeri 4mV ve gürültü seviyesi  $1\mu V_{RMS}$  (mikro volt) olan ( $1\mu V$  çözünürlük değeri olarak da belirlenebilir) EMG sinyali için 1000 kat yükseltme işlemi ve en az 13 bit çözünürlüğü gerekir [24]. Çünkü ADC'nin 10V referans gerilimi  $2^{13}-1$  seviyeye bölündüğünde 1.22mV değeri 1000 kat yükseltilmiş EMG sinyalinin çözünürlük değeri olarak hesaplanır. Bu durumda sinyal

yükseltilmeden önce  $1.22\mu\text{V}$  aralıklar ile sayısallaştırılarak, dönüşümde istenilen  $1\mu\text{V}$  çözünürlük değerine yakın bir değer elde edilmiştir. Tablo 2’de diğer örnekler verilmiştir [24].

### **1.5. Örüntü Tanıma Tabanlı Yaklaşımda EMG Sinyallerinin Ön İşlenmesi**

EMG sinyalleri elde edildikten ve sayısallaştırıldıktan sonra setler halinde bilgisayar ortamına aktarılan sinyallere ait kayıtlar, işlenmeden önce çeşitli ön işleme adımlarından geçirilmelidir. Bu adımları sırasıyla belirtecek olursak; elde edilen EMG kayıtlarının sayısal filtreler ile gürültü giderimi, EMG sinyallerinin geçici durum ve kalıcı (durağan) durum bileşenlerinin ayrıştırılması ve EMG kayıt setlerinin belirlenen boyutta pencerelelere bölünmesi (segmentasyonu) işlemleridir.

#### **1.5.1. Gürültü Giderme**

EMG sinyallerine uygulanan gürültü giderme işlemleri sinyalin yükseltilmesi sırasında analog filtreler ile gerçekleştirilirken sinyal ADC işlemleri sonucu ayırık hale getirildikten sonra sayısal filtreler kullanılarak gerçekleştirilir.

EMG sinyalleri yükseltilmeden önce yüzey elektrotlarının deri ile teması esnasında meydana gelen hareketler ve kablo hareketlerinden kaynaklanan düşük frekanslı 15-30 Hz aralığında gürültü bileşenleri sinyale karışır [24,25]. İlk yükseltme işleminden sonra bu gürültü bileşenleri donanımsal (analog) yüksek geçiren filtre ile bastırılır. Aynı şekilde yükseltilmiş EMG sinyallerini çıkışa vermeden önce elektronik devre elemanlarından ve diğer çevre bileşenlerinden kaynaklı yüksek frekanslı gürültüleri gidermek için devrenin son çıkışına 450-500 Hz donanımsal alçak geçiren filtre uygulanır. Şebeke geriliminden kaynaklı 50/60 Hz gürültünün giderilmesi için çentik (notch) filtrenin uygulanıp uygulanmaması elde edilecek EMG sinyallerinin hangi özelliklerinin incelendiğine bağlıdır. 50/60 Hz frekanslı sinyaller EMG sinyallerinin baskın frekans (30-150 Hz) bandında yer alır. Çentik filtre uygulanması sonucu önemli veriler gürültü bileşenleriyle kaybedilecek ayrıca merkez frekansın altına ve üstüne uzanan faz rotasyonu başlamasıyla EMG sinyallerinin dalga şekli de önemli ölçüde değişecektir [24]. Eğer sinyalin genliği

veya gücüyle ilgili özellikler inceleniyorsa faz rotasyonu sorunu çok önemli bir durum değildir [24,26].

EMG sinyallerinin yükseltilmesi sırasında her ne kadar çeşitli analog filtreler uygulansa da sayısal EMG sinyallerinin işlenmeden önce bazı düşük ve yüksek frekans bileşenlerini temizlemek için sayısal filtrelerle gürültü giderme işlemleri gerçekleştirilmelidir. EMG sinyalleri üzerinde uygulanan sayısal filtreleme işlemleri genel olarak iki farklı yöntemle gerçekleştirilir. Bunlar geleneksel gürültü giderme ve dalgacık dönüşümü ile gürültü giderme yöntemleridir.

#### **1.5.1.1. Geleneksel Gürültü Giderme**

Sayısal EMG sinyalleri üzerine yüksek geçiren ( $>30$  Hz), alçak geçiren ( $<500$  Hz) ve bant durduran (50 Hz) sayısal filtrelerin uygulanması işlemleri geleneksel gürültü giderme işlemleridir. Belirli frekans aralıklarına uygulanan bu filtrelemeler EMG sinyalinin baskın enerjisinin olduğu frekans aralığında olan gürültüleri temizlemede yeterli değildir [27]. EMG sinyaline karışmış bu tür gürültüleri temizleyebilmek için ayrık dalgacık dönüşümü (ADD) ile gürültü giderme işlemleri uygulanmalıdır [24,27,28].

#### **1.5.1.2. Dalgacık Dönüşümü ile Gürültü Giderme**

Dalgacık dönüşümü (DD) ile gürültü giderme ilk olarak Donoho [29] tarafından önerilmiştir. Donoho'nun yöntemi 3 adımda özetlenebilir [30]. Bu adımlar; öncelikle gürültülü sinyal dalgacık dönüşümü ile yaklaşıklık ve detay katsayılarına ayrıştırılır. Daha sonra elde edilen detay katsayılarına uygun bir eşik değeri uygulanır. Son olarak yaklaşıklık ve modifiye edilmiş detay katsayıları kullanılarak ters dalgacık dönüşümü ile sinyal tekrar oluşturulur. ADD ile gürültü giderme performansının değerlendirilmesi iki şekilde gerçekleştirilir [27]. İlki; gürültülü sinyal ile temizlenmiş sinyalin sınıflandırma başarılarının karşılaştırılması diğeri ise orijinal sinyal ile bu sinyale Beyaz Gauss gürültüsü eklenerek elde edilen yeni sinyal kullanılarak ortalama hataların karesi (Mean-Square Error MSE)'nin hesaplanmasıdır. MSE ne kadar küçük çıkarsa gürültülü sinyalin o

kadar iyi temizlendiği anlamına gelir. MSE hesaplaması için Matlab (MathWorks Inc.) programında yazılan kodlar Ek1’de verilmiştir.

Dalgacık dönüşümü gürültü giderme işlemlerinin uygulanabilmesi için belirlenmesi gereken 5 parametre vardır. Bunlar;

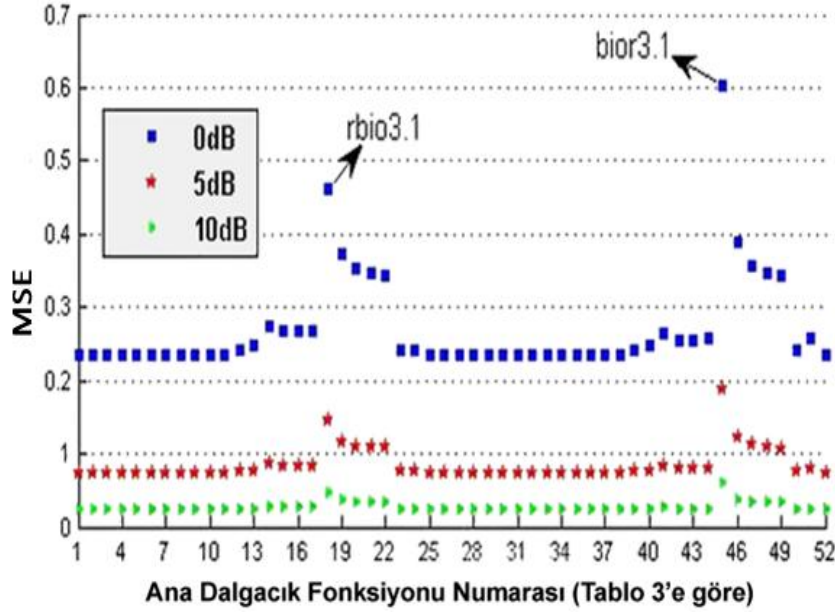
1) Ana dalgacık temel fonksiyonu seçimi: Sürekli Dalgacık Dönüşümü (SDD) işleminde uygulanacak ana dalgacık fonksiyonunun seçimi frekans bileşenlerinin çıkartılması için önemli bir parametredir. Ana dalgacık seçiminde kullanılacak fonksiyonlar Tablo 3’de gösterilmiştir.

Tablo 3. Ana dalgacık fonksiyonları

Ana dalgacık fonksiyonu numarası	Ana dalgacık fonksiyonları (Dalgacık fonksiyonu numarasına göre sıralı)
1 - 10	db1, db2, db3, db4, db5, db6, db7, db8, db9, db10
11 - 24	rbio1.1, rbio1.3, rbio1.5, rbio2.2, rbio2.4, rbio2.6, rbio2.8, rbio3.1, rbio3.3, rbio3.3, rbio3.5, rbio3.7, rbio3.9, rbio4.4, rbio5.5
25 - 29	coif1, coif2, coif3, coif4, coif5
30 - 37	sym1, sym2, sym3, sym4, sym5, sym6, sym7, sym8
38 - 52	bior1.1, bior1.3, bior1.5, bior2.2, bior2.4, bior2.6, bior2.8, bior3.1, bior3.3, bior3.5, bior3.7, bior3.9, bior4.4, bior5.5, bior6.8

Bu tezdeki veri setleri kullanılarak yapılan [30]’daki çalışmada EMG sinyalleri üzerinde uygulanan dalgacık gürültü giderme işlemlerinde ana dalgacık fonksiyonu ve MSE’ye göre elde edilen sonuçlar Şekil 7’de gösterilmiştir.

Şekil 7 incelendiğinde EMG sinyalleri üzerinde dalgacık gürültü giderme için seçilebilecek ana fonksiyonlar daubechies (db1..db10), symlet (sym1..sym8) ve coiflet (coif1..coif5)’dir. MSE değeri yüksek çıkan reverse biorthogonal (rbio3.1) ve biorthogonal (bior3.1) fonksiyonları ise EMG sinyallerinin dalgacık gürültü giderilmesi işlemleri için önerilmez.



Şekil 7. Ana dalgacıklara göre ortalama kareler hatası

2) Dalgacık dönüşümü ayrıştırma seviyesinin belirlenmesi: Zaman düzlemindeki örnek uzunluğu  $N$  olan bir veri setinin maksimum ayrışma seviyesi  $J$  (1)'e göre hesaplanır [31]. EMG sinyalleri için dalgacık dönüşümü ayrışma seviyesinin 4 seçilmesi uygundur.

$$J = \log_2 N \quad (1)$$

3) Eşik seviyesi seçim yönteminin belirlenmesi: 4 temel eşik seçim yöntemi vardır. Donoho'nun Evrensel Eşik Seçim (Universal Threshold Selection) Yöntemi, Stein'in Tarafsız Risk Tahmini (Unbiased Estimate of Risk-SURE) Yöntemi, Donoho ve Johnstone SURE yönteminin sınırlamalarının üstesinden gelmek için önerdikleri Evrensel ve SURE yöntemlerinin karışımı olan Hibrid Yöntemi ve Stein tarafından önerilen Minimaks Yöntemidir [31]. Araştırmaların genelinde kullanılan ve en iyi gürültü giderme performansı sunan Evrensel Eşik Seçim Yöntemidir [31]. Donoho'nun eşik seviyesi seçim yöntemi (2)'de verilmiştir.  $N$  zaman düzlemindeki sinyalin örnek sayısı,  $\sigma$  ise gürültünün standart sapmasıdır. Bu değer dalgacık dönüşümü sonucu elde edilen her ölçek seviyesindeki ( $j$ ) detay katsayıları mutlak değerinin ( $|cD_j|$ ) medyan parametresinin 0.6745 sabitine (normalleştirme faktörü) bölünmesiyle hesaplanır.

$$Eşik_{Seviyesi} = \sigma \sqrt{2 \log(N)} \quad (2)$$

4) Eşik yeniden ölçeklendirme yönteminin belirlenmesi: Eşik seviyesi seçim yöntemiyle elde edilecek eşik değerinin yumuşatılması için kullanılan yöntemdir[31]. Eşik seviyesi hesaplanırken kullanılacak standart sapmanın ( $\sigma$ ) tüm seviyelere göre, ilk seviyeye göre veya seviyelere bağlı olarak hesaplanacağına karar verir.

5) Eşikleme fonksiyonunun belirlenmesi: Eşik seviyesi değeri belirlendikten sonra dalgacık katsayıları üzerinde eşikleme gerçekleştirilir. Birçok eşikleme fonksiyonu vardır [31]. Yaygın olarak, sert eşikleme (3) ve yumuşak eşikleme (4) kullanılır. [31]' deki çalışmada yumuşak eşikleme fonksiyonunu temel alan adaptif eşikleme fonksiyonu ile yüzey EMG sinyallerinin gürültü gidermesinde daha küçük MSE değeri elde edildiği gösterilmiştir. Adaptif eşikleme fonksiyonu ise (5)'de verilmiştir. Formüllerde verilen cDj j. seviyenin detay katsayılarını, EDj j. seviyenin eşik değerini ve sgn signum fonksiyonunu belirtir. Signum fonksiyonu (6)'da verilmiştir.

$$cDj = \begin{cases} cDj, & \text{Eğer } |cDj| > EDj \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (3)$$

$$cDj = \begin{cases} \text{sgn}(cDj)(|cDj| - EDj), & \text{Eğer } |cDj| > EDj \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (4)$$

$$cDj = cDj - EDj + \frac{2EDj}{1 + e^{\frac{2.1cDj}{EDj}}} \quad (5)$$

$$\text{sgn } x = \begin{cases} -1, & x < 0 \\ 0, & x = 0 \\ 1, & x > 0 \end{cases} \quad (6)$$

Tablo 4'te yüzey EMG sinyallerine uygulanan dalgacık dönüşümü ile gürültü gidermede kullanılan parametreler gösterilmiştir.



Tablo 4. Dalgacık dönüşümü gürültü giderme için seçilebilecek parametreler

Dalgacık gürültü giderme parametresi tipi		Referans [31]	Referans [30]
Dalgacık ana fonksiyonu seçimi	En iyi sonuç verenler	db1,bior1.1 ve rbio1.1	db4, db9, sym1
	Ortalama iyi sonuç verenler	db2,db7,sym2,bior5.5, rbio2.2	db10, sym3, coif3, coif5
	Kötü sonuç verenler	bior3.1	bior3.1, rbio3.1
Ayrışma seviyesi		4	4
Eşik seviyesi seçim yöntemi		Evrensel	Evrensel
Eşik yeniden ölçekleme		N ve $\sigma$ için seviyeye bağlı	N ve $\sigma$ için seviyeye bağlı
Eşikleme fonksiyonu		Adaptif	Adaptif

### 1.5.2. Sinyalin Bölütlere Ayrılması

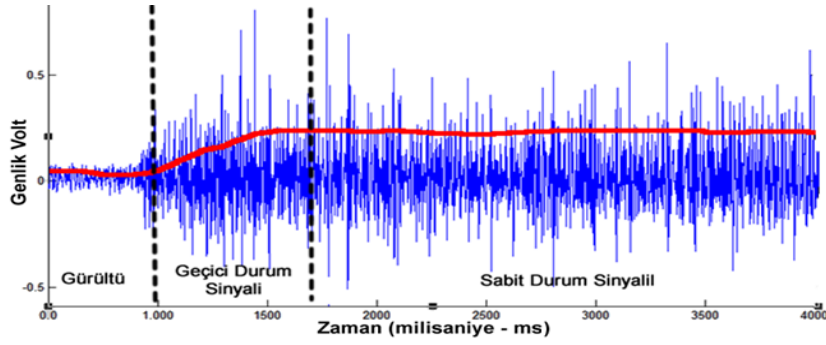
EMG sinyallerinin ön işlenmesinde son olarak bölütlere ayırma (pencereleme) işlemi uygulanır. Bu bölümde sinyalin geçici durum veya kalıcı durum bileşenlerinin ayrıştırılması ve uygulanacak pencerelemeyle ilgili işlemler gerçekleştirilir.

#### 1.5.2.1. Geçici Durum ve Kalıcı Durum Bileşenleri

Geçici durum; sinyal elde edilirken kasın dinlenme anından başlayıp kasılmanın ateşlenmesi bölgesini kapsayan zamandaki EMG sinyalleridir. Kalıcı durum sinyalleri ise kasın sabit kasılma zamanında elde edilen EMG sinyalleridir. Şekil 8’de geçici ve kalıcı durum EMG sinyalleri gösterilmiştir.

Miyoelektrik kontrol sistemlerinde geçici durum sinyalleri kullanılmasının oluşturduğu en önemli dezavantaj, kasılmanın kasın dinlenme durumundan başlatılıyor olmasıdır [32]. Bu durum kontrol sisteminin sezgisel ya da etkili bir şekilde bir sınıftan diğer bir sınıfa geçişini ve birden fazla serbestlik derecesi olan karmaşık görevlerin koordinasyonunu engeller [32]. Kalıcı durum EMG sinyallerinin sınıflandırma başarısının geçici durum EMG sinyallerininkinden daha iyi olduğu ve geçici durum sinyallerinde

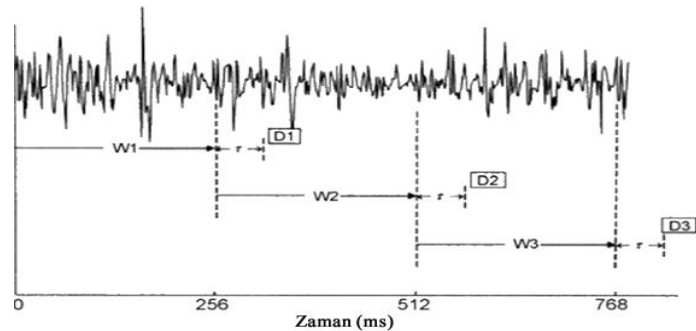
pencere boylarının küçültülmesiyle (pencere boyu 128 ms'den 32 ms yapıldığında başarı yaklaşık %50 azalmıştır) sınıflandırma doğruluğunun hızlı bir şekilde düştüğü belirtilmiştir [33].



Şekil 8. Geçici ve kalıcı durum EMG sinyalleri


### 1.5.2.2. Pencereleme

EMG sinyallerinin gerçek zamanlı işlenmesinde pencereleme yöntemi ve pencerelerin boyu önemlidir. Küçük pencere boylarında sinyale ait çok daha az özellikler yer alacağı için hareket sınıfını tanıma doğruluğu azalacaktır. Daha fazla özellik elde edebilmek amacıyla pencere boyunun artırılması ise gerçek zaman sınırının aşılmasına sebep olacaktır. Aktif el ve kol protezlerinde tepki süresi gerçek zaman sınırlaması yaklaşık 300 ms'dir [32,33,34]. Bu sebeple belirlenecek pencere boyunun 300 ms'den az olması gerekmektedir.



Şekil 9. Bitişik (adjacent) pencereleme

Pencereleme yöntemi EMG sinyal seti boyunca her bir pencerenin bitişik (adjacent) mi yoksa örtüşmeli(overlapped) mi ilerletileceğiyle ilgilidir. Eğer veriyi işleme süresi pencere boyundan daha kısa sürede gerçekleşiyorsa işlemci için boş bir zaman oluşacaktır [32]. Bitişik pencereleme yönteminin kullanılmasıyla işlemci boşa kalan zamanını daha fazla sınıflandırma çıkışı için harcar [32]. Şekil 9’da bitişik pencereleme ve Şekil 10’da ise örtüşmeli pencereleme gösterilmiştir. Şekil 9 ve Şekil 10’da,  $\tau$  işleme zamanını D1, D2, D3 karar verme zamanlarını belirtir. W1,W2,W3 pencereleri bitişik pencereleri; R1, R2, R3 ise örtüşmeli pencereleri gösterir.



Şekil 10. Örtüşmeli (overlapped) pencereleme

### 1.6. EMG Sinyallerinin Öznitelikleri

EMG sinyalleri öznitelikleri genel olarak 3 bölüme ayrılabilir. Bunlar; zaman düzlemi (ZD) öznitelikleri, frekans düzlemi öznitelikleri ve zaman-frekans düzlemi (ZFD) öznitelikleridir. En iyi özniteliklerin kullanılması sınıflandırma başarısı için en önemli adımdır. EMG sinyallerinin durağan olmayan yapısından dolayı sadece frekans düzlemi özniteliklerinin kullanılması uygun değildir. EMG sinyallerinde kullanılan özniteliklerin çoğu, zaman düzlemi öznitelikleridir. ZD öznitelikleri hem klinik hem de örüntü tanıma tabanlı uygulamalarda iyi sonuçlar vermektedir. Son zamanlarda uygulanan ZFD düzlemi öznitelikleri de sınıflandırma başarısına oldukça katkı sağlar.

Bu bölümde EMG sinyallerinin örüntülerini sınıflandırabilmek için yaygın olarak kullanılan ve bu çalışmada da büyük bir bölümünün kullanıldığı ZD ve ZFD özniteliklerine değinilecektir.

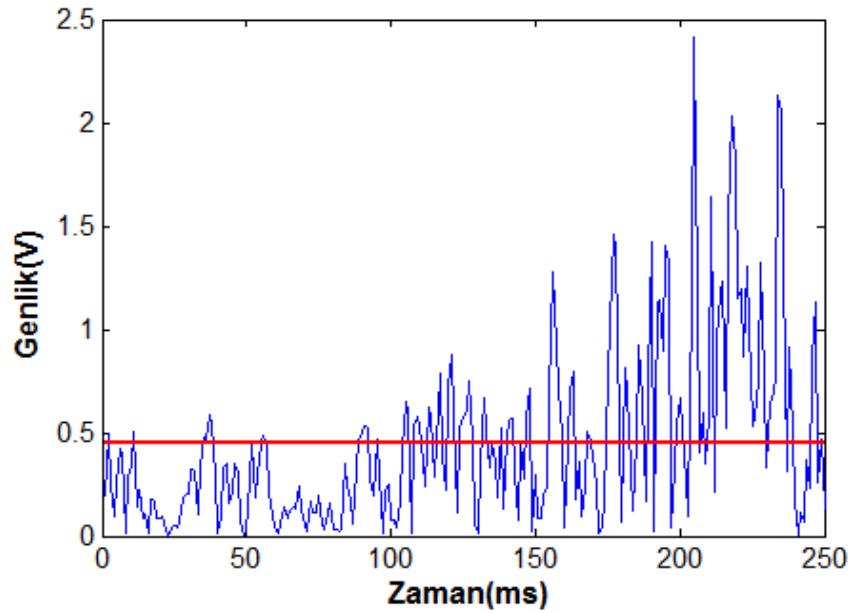
### 1.6.1. Zaman Düzlemi Öznitelikler

Zaman düzlemi öznitelikleri basit ve hızlı hesaplanabilir. Çünkü bu öznitelikler için herhangi bir dönüşüm işlemi yapılmaz [26,35]. Hesaplama basitliğinden dolayı EMG sinyallerinin gerçek zamanlı olarak özniteliklerinin çıkartılması için de uygundur [36]. Bu özniteliklerden yaygın olarak kullanılanların matematiksel ifadeleri aşağıda sıralanmıştır.

1) Ortalama Mutlak Değer (OMD) : Her bir pencerenin içerdiği örneklerin mutlak değerlerinin ortalaması alınarak hesaplanır (7).

$$X_i = \frac{1}{N} \sum_{k=1}^N |x_k| \quad (7)$$

N her bir pencerenin boyunu, k pencerelerdeki her bir örneği ve i bir setteki toplam pencere sayısını ifade eder. Bilek bükme hareket sınıfına ait örneklerden alınan 250 ms'lik pencerenin hesaplanmış OMD değeri Şekil 11'de kırmızı çizgi ile gösterilmiştir



Şekil 11. Bir pencereye ait hesaplanan ortalama mutlak değer


2) Modifiye Edilmiş Ortalama Mutlak Değer (mOMD) : Her bir pencerenin belirli sayıda bölünmesiyle oluşan alt pencerelerinin OMD değerleri farkıdır (8,9). I-1 ayrılacak alt pencere sayısını verir.

$$\Delta X_i = X_{i+1} - X_i, \quad i = 1, \dots, I-1 \quad (8)$$

$$mOMD = \sum_{i=1}^{I-1} \Delta X_i \quad (9)$$

2) Ortalama Mutlak Değer Eğimi (OMDE) : Her bir pencerenin belirli sayıda bölünmesiyle oluşan alt pencerelerinin OMD değerleri farkıdır (10). I her bir pencerenin kaç bölüme ayrılacağını belirtir.  $X_i$ 'ler alt pencerelerin OMD değeridir. Şekil 12'de bilek bükme hareket sınıfına ait örneklerden alınan 250 ms'lik pencerenin I=5 değeri için hesaplanmış OMDE değerleri kırmızı çizgilerle gösterilmiştir. Bu öznitelikte her bir pencereden I-1 adet öznitelik değeri elde edilir.

$$\Delta X_i = X_{i+1} - X_i, \quad i = 1, \dots, I-1 \quad (10)$$



Şekil 12. Bir pencereye ait I=5 için hesaplanan OMDE değerleri


3) Sıfır Geçiş Tespiti Sayısı (SGTS) : Her bir pencere içerisinde sinyalin pozitif bir değerden sıfır değerine ya da negatif bir değerden sıfır değerine ulaştığı yerlerin tespit edilerek sayılmasıdır (11).  $\cap$  'Ve' bağlacı, sgn ise signum fonksiyonudur (6). Sıfır geçiş tespiti sayısının gürültüden etkilenmemesi için belirli bir eşik değeri uygulanır [26]. Eğer sgn pozitif bir değer döndürürse ve o anki örnekle bir sonraki örneğin farklarının mutlak değeri eşik seviyesinden büyükse SGTS'nin değeri bir artırılır.

$$SGTS = \sum_{k=1}^N [\text{sgn}(-x_k \times x_{k+1}) \cap |x_k - x_{k+1}| \geq \text{eşik}] \quad (11)$$

SGTS özneteliği için (10) da belirtilen denklemleri daha açık olarak yazacak olursak;

$$\{ [ (x_k > 0) \text{ ve } (x_{k+1} < 0) ) \text{ veya } ( (x_k < 0) \text{ ve } (x_{k+1} > 0) ) ] \text{ VE } [ |x_k - x_{k+1}| \geq \text{eşik} ] \}$$

sonucu doğru (true) ise sıfır geçiş tespit edilmiş olup, SGTS değeri bir artırılır [37].



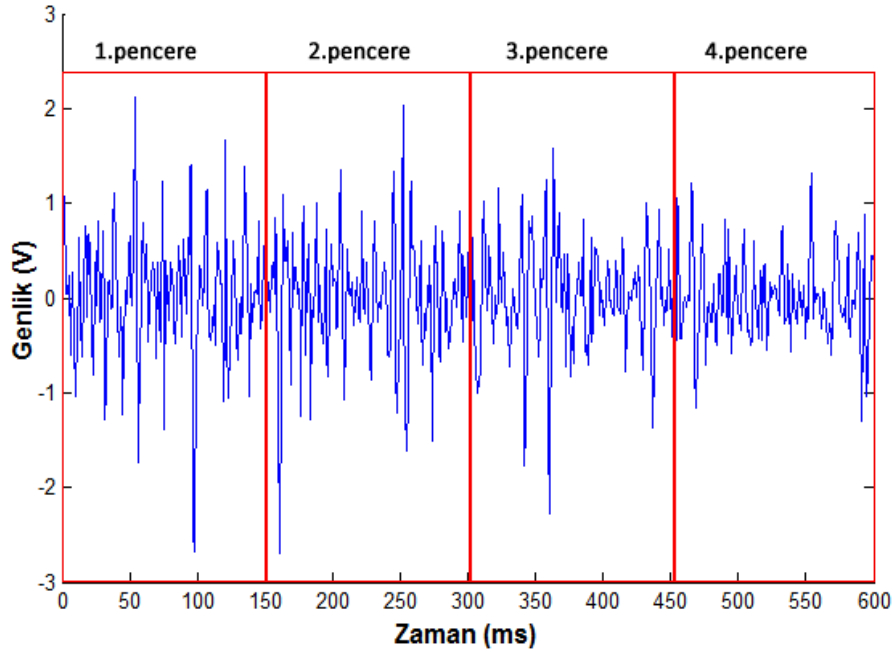
Şekil 13. Bir pencereye ait eşik değeri 0,3 olan SGTS yerleri

Şekil 13'te bilek germe hareket sınıfına ait örneklerden alınan 100 ms'lik pencere üzerinde 0,3 eşik değeri için tespit edilen yerler gösterilmiştir. Burada art arda gelen iki örnek arasında sıfır noktasından geçişin olması ve bu örneklerin mutlak değerleri farkının

0,3 değerine eşit veya 0,3 değerinden büyük olması durumları sayılmıştır. Bu pencerede SGTS değerinin 8 olduğu tespit edilmiştir.

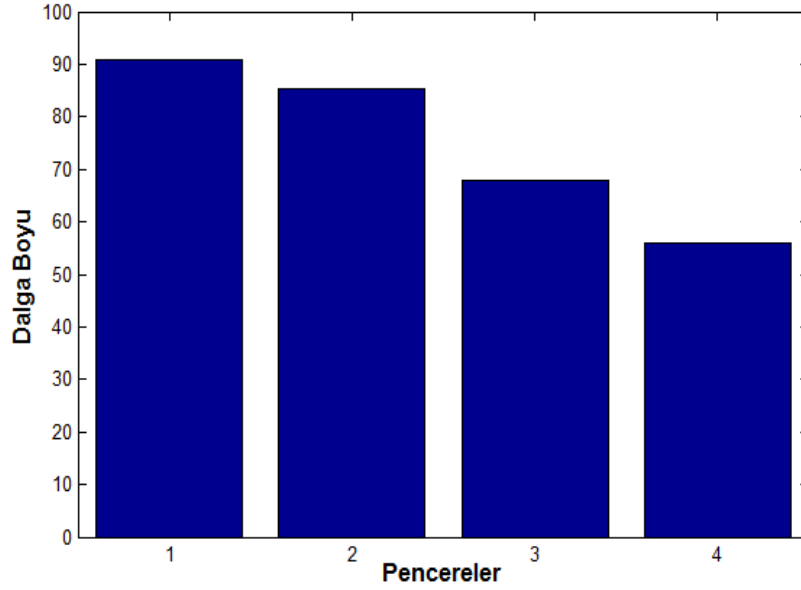
4) Dalga Boyu (DB) : Pencere boyunca örnekten örneğe genliklerdeki artan değişimleri ölçer (12).

$$DB = \sum_{k=2}^N |x_k - x_{k-1}| \quad (12)$$



Şekil 14. 4 pencereden oluşan 600 ms'lik bir sinyal

Şekil 14'te bilek bükme hareket sınıfına ait örneklerden alınan ve 150 ms'lik 4 pencereden oluşan toplam 600 ms'lik sinyal verilmiştir. Her bir pencere için hesaplanan dalga boyu özneliği değeri ise Şekil 15'te gösterilmiştir. Şekil 15 incelendiğinde 1. ve 2. pencerenin dalga boyu değerleri yakın çıkmıştır. 3 ve 4. pencerelerin dalga boyları ise 1 ve 2. pencerelere göre daha küçük değerdedir. 1 ve 2. pencerelerde örnekten örneğe genlikteki değişimlerin 3 ve 4. pencerelerinkinden daha fazla olduğu Şekil 15'ten anlaşılmaktadır.



Şekil 15. Dalga boyu özniteliği değerlerinin gösterimi

5) Willison Genliği (WG) : EMG sinyali genliğini belirlenen bir eşik değeri ile karşılaştırarak bu eşik değerinin üzerindeki genlikleri sayar (13).

$$WG = \sum_{k=2}^N f|x_k - x_{k-1}| \quad (13)$$

Eğer  $f(x)$  belirlenen eşik değerinden büyükse 1 diğer durumlarda 0 değeri üretir.


6) Özbağlanım Katsayıları (autoregressive AR) : Çoğu sistem geçmişteki çıkışlarının, o anda ki ve geçmişteki girişlerinin doğrusal kombinasyonları ile modellenebilir [38,39]. EMG sinyalleri, durağan olmayan ve doğrusal olmayan özellikte olmasına rağmen kısa zaman aralıklarında durağan Gauss süreci olarak kabul edilebilir [26,38,39].

$$X_k = \sum_{i=1}^p a_i X_{k-1} + e_k \quad (14)$$

Eşitlik (14)'te  $X_k$ , herhangi bir ayrık zamandaki tahmin edilen işareti,  $a_i$  AR model parametrelerini,  $p$  modelin derecesini,  $e_k$  ise beyaz gürültüyü (hesaplanmış değer)

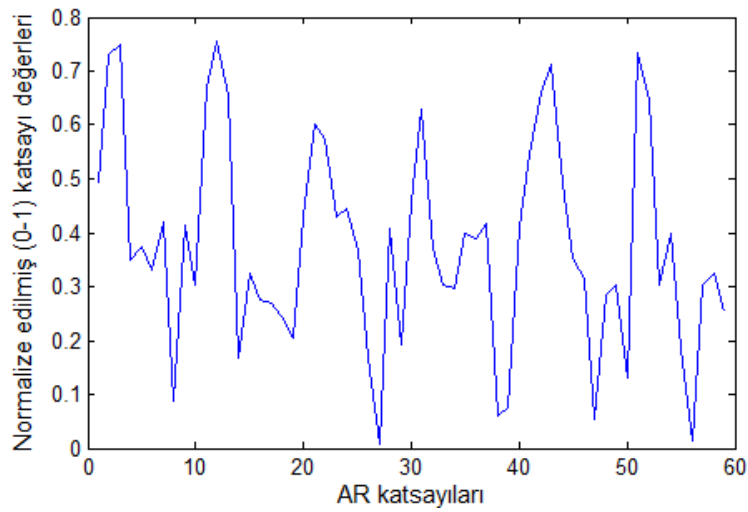


hatasını) ifade eder. AR modeli sistemin çıkışlarını kullanarak modelleme yapar. Bu modellemede (14)  $a_i$  AR modeli parametrelerinin elde edilmesi (kestirilmesi) gerekmektedir. Yule Walker, Burg, Kovaryans ve Değiştirilmiş Kovaryans gibi parametre kestirim yöntemlerinden biri kullanılabilir.



Şekil 16. 6 tekrarlı bilek bükme hareket sınıfına ait EMG kaydı

Şekil 16'da bilek bükme hareket sınıfına ait fleksör kasından alınan 6 tekrarlı 5 saniyelik kasılmalardan oluşan toplam 30 saniyelik EMG kaydı verilmiştir.



Şekil 17. AR katsayıları

Şekil 16'daki EMG kayıtları 500 ms'lik pencerelere bölünüp her bir pencerenin 4. derece AR modelinin ilk katsayılarıyla elde edilen sonuç Şekil 17'de gösterilmiştir. Şekil 17 incelendiğinde her bir pencere için elde edilen 4 katsayıdan ilki sinyalin genlik modelini belirli bir şekilde çıkartmıştır.

7) Eğim Gösterge Değişikliği (EGD): Ardı ardına gelen 3 örneğin pozitif ve negatif eğim arasındaki değişim sayısını izler [36]. Eşik seviyesi kullanılarak arka arkaya gelen sadece önemli değişikliklerin sayılması sağlanabilir [36]. (16)'da her bir nokta için  $f(X)$  hesaplanır. Bu hesaplamanın sonuca göre EGD değeri, (15)'ten elde edilir.

$$EGD = \sum_{k=2}^{N-1} [ f[(x_k - x_{k-1})x(x_k - x_{k+1})] ] \quad (15)$$

$$f(X) = \begin{cases} 1, & \text{Eğer } X \geq \text{Eşik} \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (16)$$

EGD özneliği için (15) ve (16) da belirtilen denklemi daha açık olarak yazacak olursak;

{ [ ( (xk > xk-1) ve (xk > xk+1) ) VEYA ( (xk < xk-1) ve (xk < xk+1) ) ] VE [ ( | xk - xk+1 | ≥ eşik) veya ( | xk - xk-1 | ≥ eşik) ] } sonucu doğru (true) ise EGD değeri bir artırılır [37].

### 1.6.2. Zaman-Frekans Düzlemi Öznitelikler

EMG sinyallerinin ZFD öznitelikleri olarak kısa zaman Fourier dönüşümü (KZFD), ayrık dalgacık dönüşümü katsayıları ve ayrık dalgacık paket dönüşümü (ADPD) katsayıları kullanılır. EMG sinyallerinin durağan olmayan yapısı doğru bir öznitelik çıkarmayı zorlaştırmaktadır [8]. Bu sebeple parametrik olmayan zaman – frekans gösterimleri EMG sinyallerinden öznitelik çıkarmak için iyi bir yaklaşımdır [8].

### 1.6.2.1. Sürekli ve Ayrık Dalgacık Dönüşümü

Bir sinyale ait frekans bileşenlerini çıkartmak için Fourier dönüşümü sıkça kullanılan iyi bir yöntemdir. Fakat Fourier dönüşümü durağan olmayan sinyallerin frekans bileşenlerine ait zaman bilgisini içermediği için bu tür sinyallerin zaman-frekans bilgilerini çıkartmada yetersizdir. Durağan olmayan sinyaller bir pencere fonksiyonuyla bölütlenerek elde edilen her bir parçaya Fourier dönüşümü uygulanır ve pencere sinyal boyunca zamanda kaydırılarak sinyalin kısa zamanlarda Fourier dönüşümü yapılmış olur (KZFD). Her bir pencerelerin zaman boyunca kaydırılmasıyla frekanslara ait zaman bilgisi de çıkartılmış olur. KZFD'de geniş pencere seçilirse iyi frekans çözünürlüğü elde edilirken zaman çözünürlüğü azalır. Tersisi durumda yani dar pencere seçilmesi iyi zaman çözünürlüğüne karşın zayıf frekans çözünürlüğü elde edilir. Bu durum durağan olmayan sinyallerin zaman –frekans bileşenlerinin tam çıkartılamamasına neden olur. Sinyal üzerinde zaman boyunca pencerelerin sabit boyda kaydırılması bu durumun doğal sonucudur. Bu sebeple günümüzde, durağan olmayan sinyallerin zaman- frekans çözünürlüğüne göre boyu değişebilir pencereler uygulama imkanı sunan dalgacık dönüşümü yöntemi yaygın olarak kullanılır. Dalgacık dönüşümü Fourier dönüşümüne göre daha hızlı hesaplanır. Dalgacık dönüşümünün büyük  $O$  notasyonu  $O(n)$  (doğrusal) iken hızlı Fourier dönüşümünün  $O(n \log n)$ 'dir (doğrusal logaritmik).

Sürekli Dalgacık Dönüşümünün (SDD) matematiksel ifadesi (17,18) verilmiştir. Burada  $\Psi$  reel değerli ( $s \neq 0$  şartıyla) ana dalgacık fonksiyonunu,  $s$  ölçeği,  $\tau$  konumu ve  $x(t)$  dönüşümü yapılacak sinyalin fonksiyonunu belirtir (17).


$$\text{SDD}(\tau, s) = \frac{1}{|\sqrt{s}|} \int_{-\infty}^{\infty} x(t) \Psi_{s, \tau}^*(t) dt \quad (17)$$

$$\Psi_{(s, \tau)} = \frac{1}{|\sqrt{s}|} \Psi\left(\frac{t-\tau}{s}\right) \quad (18)$$

SDD'de, ana dalgacık (mother wavelet) olarak adlandırılan örnek bir pencerenin kaydırılmış (ötelenmiş) ve ölçeklendirilmiş durumlarıyla bir  $x(t)$  sürekli sinyalin

ilişkilendirilmesidir [8,40]. Bu ilişkilendirme belirlenen ölçekteki ana dalgacık fonksiyonunun dönüşümü yapılacak sinyalin zaman ekseninde kaydırılarak çarpılmasıyla elde edilen değerlerin toplamından oluşan katsayılar ile gerçekleştirilir.

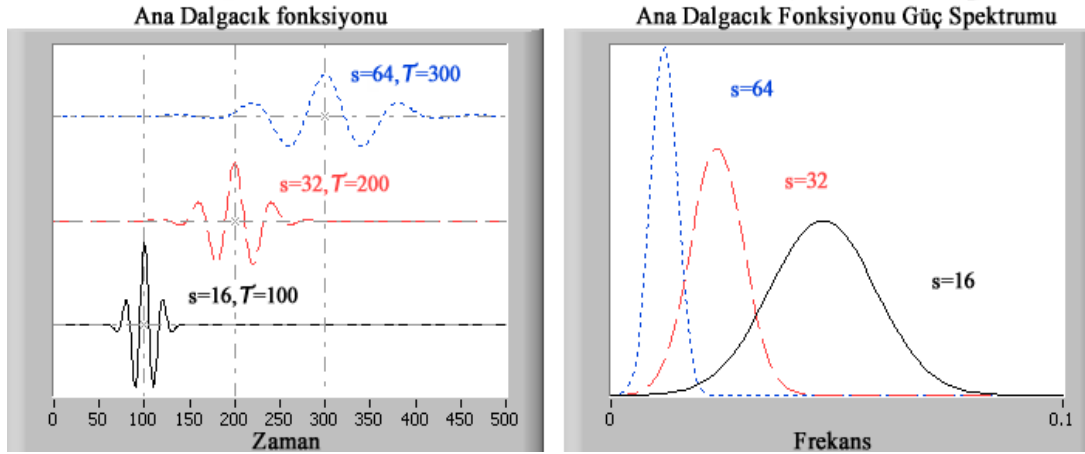
Dönüşüm sonucu elde edilen katsayı (C) değerlerinin yüksek çıktığı yerlerde, ana dalgacık fonksiyonu ile dönüşümü yapılan sinyalin çarpım bölgesinin benzer olduğu, katsayı değerlerinin düşük hesaplandığı yerlerde ise benzerliğin az veya hiç olmadığı anlaşılır. (17)'de verilen  $\tau$  kaydırılan ana dalgacık fonksiyonunun dönüşümü yapılan sinyalin zaman ekseninde yerini gösterir [8]. Ölçek parametresi olan  $s$  ise frekansın tersi ( $1/f$ )'dir [8]. Yani ana dalgacığın büzülmesini veya yayılmasını sağlar. Küçük ölçek değeri ( $0 < s < 1$ ) ana dalgacığı büzeceği için dönüşümü yapılan sinyalin yüksek frekans bileşenlerini (hızlı değişen bileşenler) çıkartır [8]. Eğer ölçek değeri  $s > 1$  seçilirse ana dalgacık genişleyeceği için sinyalin düşük frekans bileşenleri elde edilir [8]. Şekil 18'de farklı ölçeklerdeki frekans çözünürlükleri gösterilmektedir.



Şekil 18. Dalgacık dönüşümü zaman ölçek gösterimi [41].

Ana dalgacık fonksiyonunun farklı ölçek parametrelerinde güç spektrumu Şekil 19'da ayrı ayrı gösterilmiştir. Şekil 19'da ana dalgacık fonksiyonunun güç spektrumu incelendiğinde küçük ölçek bileşenli ana dalgacık kısa bir zaman süresine sahiptir [41]. Bu sebeple sinyal boyunca yakalamış olduğu frekans bileşenleri (yüksek frekanslı) fazla olacak (geniş frekans bandı) ve yüksek merkezi frekansa sahip olacaktır [41]. Ana dalgacık

büyük ölçek bileşeni ile geniş bir zaman süresine sahip olup, dar frekans bandı ve düşük merkezi frekans içerir [41].



Şekil 19. Ana dalgacık fonksiyonunun farklı ölçek parametrelerinde Güç spektrumu [41].

Sürekli dalgacık dönüşümü yapılacak bir sinyale tüm ölçek ve kaydırma parametrelerinin uygulanmasıyla birçok dönüşüm işlemi gerçekleştirilir. Bu işlemler sonucu sinyale ait gereksiz bilgilerinde yer aldığı birçok katsayı elde edilir. Sabit aralıklarla örneklenmiş sürekli bir sinyalin dalgacık dönüşümünün ayrık ölçeklerle ve ayrık kaydırma parametreleriyle hesaplanması SDD'nin özel bir durumu olan ayrık dalgacık dönüşümü işlemidir(ADD).

Ayrık dalgacık dönüşümünde ölçek ve kaydırma parametreleri ( $s$  ve  $\tau$ ) ayrık şekle dönüştürülür (17) [8]. Eşitlik (19)'da  $j$  ve  $n$  tam sayıdır. ADD işleminde ana dalgacık fonksiyonu yeni parametrelere göre düzenlenecek olursa (20) elde edilir [8]. Ayrık sinyallerin kolay ölçeklenebilmesi için genelde  $s_0 = 2$  seçilir.

$$s = (s_0)^j, \quad \tau = \frac{n}{(s_0)^j} \quad (19)$$

$$\Psi_{(n,j)}(t) = \frac{1}{\sqrt{s_0^j}} \cdot \Psi\left(\frac{t - ns_0^j}{s_0^j}\right) \quad (20)$$

ADD'de ana dalgacık fonksiyonu, ölçekleme fonksiyonu olan  $\varphi(t)$  ile bağlantılıdır. Ölçekleme fonksiyonu (21)'de verilmiştir.

$$\varphi_{(n,j)}(t) = \frac{1}{\sqrt{2^j}} \cdot \varphi\left(\frac{t - n2^j}{2^j}\right) \quad (21)$$

Çoğu durumda ADD için bu ifadeler yerine filtre bankaları kullanılır. Filtre bankaları birden fazla filtreyi içeren bir yapıdır. ADD işlemi;  $h(n)$  alçak geçiren bir filtre ve bu filtrenin yansıması (eşleniği) olan  $g(n)$  yüksek geçiren filtrenin kullanılmasıyla gerçekleştirilir. Bu iki filtrenin ilişkisi (22)'de verilmiştir.

$$g(n) = (-1)^n h(N - 1 - n) \quad (22)$$

Alçak geçiren ve yüksek geçiren filtreler kullanılarak ölçekleme fonksiyonu (22)'deki gibi düzenlenebilirse ana dalgacık fonksiyonları yeniden tanımlanabilir (23) [42].

$$\varphi(n) = \sqrt{2} \sum_n h(n) \varphi(2x-n) \quad (23)$$


$$\Psi(x) = \sqrt{2} \sum_n g(n) \varphi(2x-n) \quad (24)$$

Ayrık bir sinyali (23) ve (24)'de verilen birbirine bağlı alçak ve yüksek geçiren filtreler alt bantlara ayırıştırabilir. Ayırıştırma işlemi tekrarlanarak gerçekleştirilen bu filtreleme işlemine çok seviyeli ayırıştırma denir.

ADD'de alçak geçiren filtre büyük ölçekleme fonksiyonu kullanarak sinyale ait düşük frekans bileşenlerini çıkartır. Bu bileşenler yaklaşım (cA) katsayılarıyla temsil edilir. Yüksek geçiren filtre küçük ölçekleme fonksiyonu kullanarak sinyale ait yüksek frekans bileşenlerini çıkartır. Bu bileşenler ise detay (cD) katsayılarıyla temsil edilir. N noktadan

oluşan ayrık tek boyutlu bir sinyal, ilk seviye ( $j=1$ ) ayrıştırma işleminde alçak geçiren filtre çıkışında yaklaşım katsayıları elde edilirken yüksek geçiren filtre çıkışında ise detay katsayıları elde edilir. Birinci seviye ayrıştırma sonucu  $x[n]$  sinyalinin nokta sayısı her filtre için yarı yarıya seyreltilmiş olur. İkinci seviye ayrıştırma işleminde cD katsayıları korunarak ayrıştırma işlemi 1. yaklaşım katsayılarına uygulanır. Bu şekilde istenen ayrıştırma seviyesinde sinyal alt bantlara ayrılmış olur. Maksimum uygulanabilecek ayrıştırma seviyesi sayısı ise (25)'den elde edilebilir.

$$J \leq \log_2 N \quad (25)$$



Şekil 20. EMG sinyalinin ADD ile alt bileşenlere ayrıştırılması

Şekil 20'de veri setimizdeki 6 saniye kayıtlı bir EMG sinyalinin 7. seviyede ADD ile ayrıştırılması gösterilmektedir. Burada  $s$  asıl sinyali,  $a$  yaklaşım katsayılarıyla elde edilen son bileşeni ve  $d$  ise detay katsayılarıyla elde edilen her seviyedeki bileşenleri

göstermektedir. Ayırıştırma işlemi her seviyede yaklaşım katsayıları üzerinden gerçekleştiği için en son banttaki  $a_7$  katsayılarından elde edilen sinyal bileşeni gösterilmiştir. Ayırıştırılan sinyal bu katsayıların tamamı kullanılarak ters ayırık dalgacık dönüşümü ile tekrar oluşturulabilir.

### 1.6.2.2. Dalgacık Katsayıları Öznitelikleri

Yapılan çalışmalarda EMG sinyallerine ait çeşitli seviyelerde çıkartılan dalgacık katsayıları sinyale ait önemli bilgileri içeren iyi bir ayırıcıdır. Dalgacık katsayıları EMG sinyalinin zaman ve frekans enerji dağılımının yoğun bir temsilidir. ADD sonucu elde edilen yaklaşım ve detay katsayıları doğrudan öznitelik olarak kullanılabilceği gibi çıkartılan öznitelik vektörünün boyutunu azaltmak için dalgacık katsayıları kümeleri istatistikleri de kullanılabilir [43].

#### 1.6.2.2.1. Dalgacık Katsayıları Ortalama Mutlak Değeri

ADD sonrası yaklaşım ve detay katsayılarının ortalama mutlak değerlerine ait özniteliklerdir.

$$D_s = \frac{1}{N_i} \sum_{k=1}^{N_i} |d_i(k)| \quad , \quad i=1, \dots, s \quad (26)$$

$$A_s = \frac{1}{N_i} \sum_{k=1}^{N_s} |a_s(k)| \quad i=1, \dots, s \quad (27)$$

Bu ifadelerde (26,27) yer alan  $s$  dönüşümün ayırıştırma seviyesini,  $N_i$   $i$ . seviyedeki katsayıların toplam sayısını,  $d_i$   $i$ . seviyedeki detay katsayılarını ve  $D_s$  detay katsayılarının tüm seviyeler için çıkartılan ortalama mutlak değerlerini (OMD) belirtir.  $A_s$  yaklaşım katsayılarının OMD değeridir. Detay ve yaklaşım katsayıları ortalama mutlak değerinden ( $DK_{\text{OMD}}$ ) çıkartılan öznitelik vektörü ise (28)'de verilmiştir.



$$DK_{OMD} = [D_S, A_S] \quad (28)$$

### 1.6.2.2.2. Dalgacık Katsayıları Eğim Gösterge Değişikliği

$DK_{OMD}$ 'de olduğu gibi detay ve yaklaşım katsayılarının eğim gösterge değişikliği (EGD) değerlerine ait özniteliklerdir. EGD'nin matematiksel ifadesi Bölüm 1.6.1'de verilmişti. Dalgacık katsayılarının eğim gösterge değişikliğinden ( $DK_{EGD}$ ) çıkartılan öznitelik vektörü (29,30,31)'de verilmiştir.

$$D_S = \sum_{k=1}^{N_i} (EGD) \quad (29)$$

$$A_S = \sum_{k=1}^{N_s} (EGD) \quad (30)$$

$$DK_{EGD} = [D_S, A_S] \quad (31)$$

## 1.7. Sınıflandırma

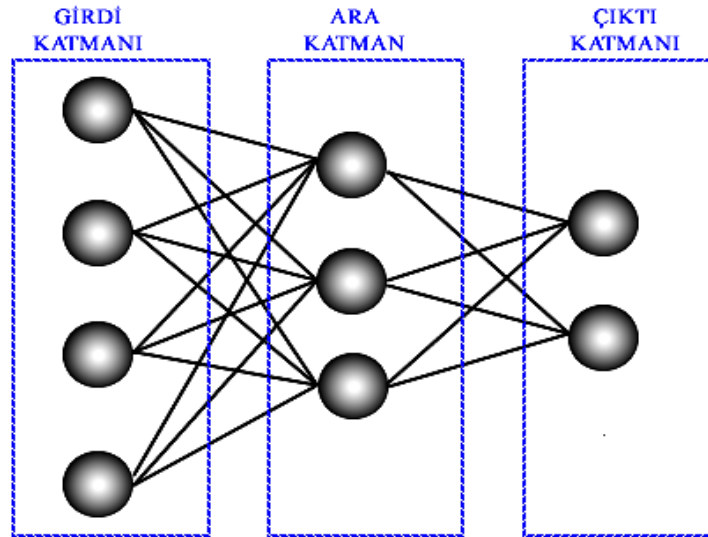
EMG sinyallerinin sınıflandırılması işlemi, farklı hareket sınıfları için çıkartılan özniteliklerin hangi hareket sınıfa ait olduğuna karar verilmesi olarak özetlenebilir. Literatür incelendiğinde EMG sinyallerinin sınıflandırılmasında kullanılan çeşitli yaklaşımlar vardır. Bunlar; sinir ağları yaklaşımı, bulanık sinir ağları yaklaşımı, bulanık yaklaşım ve istatistiksel yaklaşımlar olarak gruplanabilir [32].

Örüntü tanıma tabanlı EMG sinyallerinin sınıflandırılmasında en yaygın kullanılanlar ise, Doğrusal Ayırma Analizi (Linear Discriminant Analysis- LDA), Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları (YSA)'dır [44,45]. Sınıflandırma performansı açısından SVM, LDA ve YSA birbirlerine yakın sonuçlar verdikleri söylenebilir [32, 33,45,46]. Bu çalışmada sınıflayıcı olarak çeşitli sayıda girişlerden oluşan YSA'lar kullanılacaktır.

### 1.7.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beynindeki sinirlerin yapısı ve çalışma şekline esinlenerek oluşturulmuştur. YSA'lar kendisine verilen örneklerin girdi ve çıktıları arasındaki ilişkileri otomatik olarak ortaya çıkartan, bu ilişkileri öğrenebilen, elde ettiği bilgileri saklayabilen, bilgiler üzerinden genelleme yapabilen ve bu özellikleriyle doğrusal olmayan problemlerin çözümünde yaygın olarak kullanılan bir yöntemdir. Bir yapay sinir ağı, insan beyninde olduğu gibi nöron adı verilen yapay sinir hücrelerinin birbirlerine bağlanmasıyla oluşur. Her bir bağlantı belirli bir değer içerir. Bir yapay sinir ağının eğitilmesi sürecinde kendisine gösterilen örneklerden öğrendiği bilgileri yapay sinir hücrelerinin bağlantı değerlerinde tutar. Daha sonra bu bilgiler ile ağın girişine benzer örneklerin girdisi sağlandığında nasıl bir çıktı vereceğini öğrenmiş olur.

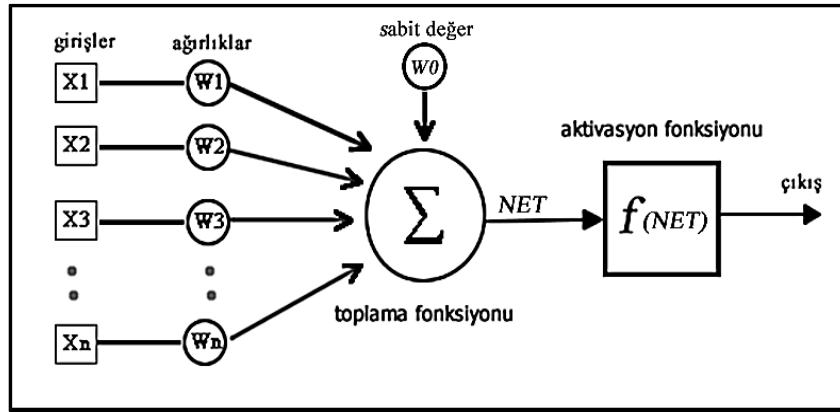
YSA, yapay sinir hücrelerinin çeşitli şekillerde birbirlerine bağlanmasıyla gerçekleşen çeşitli katmanlar (çok katmanlı) şeklinde tasarlanır. Genelde ağı oluşturan katmanlar girdi katmanı, ara katman (gizli katman) ve çıktı katmanıdır. Şekil 21'de örnek bir yapay sinir ağı modeli gösterilmiştir. Bu model bir sonraki bölümlerde ayrıntılı olarak işlenecektir. Şimdi bir yapay sinir hücresinin(nöron) yapısını inceleyelim.



Şekil 21. Yapay sinir ağı örneği

### 1.7.1.1. Yapay Sinir Hücresi Modeli

Yapay sinir hücreleri YSA'yı oluşturan en temel birimlerdir. Yapay sinir hücresinin (nöron) 6 elemanı vardır. Bu elemanlar; girişler ( $x_i$ ), ağırlıklar ( $w_i$ ), sabit değer, toplama fonksiyonu, aktivasyon(transfer) fonksiyonu ( $f$ ) ve nöronun çıkış değerinden oluşur. Örnek bir yapay sinir hücresi yapısı Şekil 22'de gösterilmiştir.



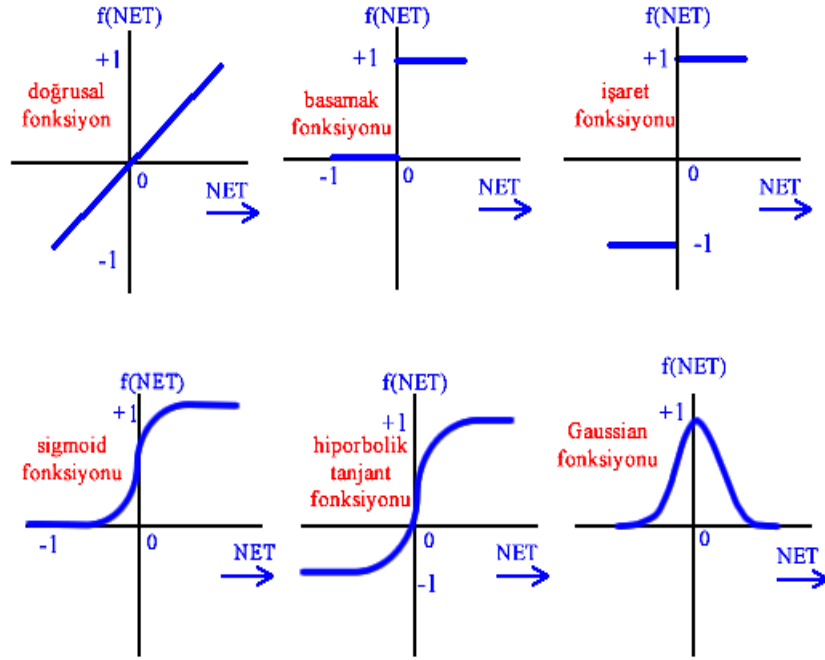
Şekil 22. Yapay sinir hücresinin (nöron) yapısı

Girişler, ağa ilk verilen girdilerden veya farklı katmandaki yapay sinir hücrelerinin çıkışından gelen değerlerdir. Ağırlıklar, girişlerin bu nöron için önemini gösteren bir katsayı değeridir. Bu sebeple giriş değeriyle çarpılır. Ağırlıklandırılmış giriş değerleriyle sabit değer toplanarak hücreye gelen net değer toplama fonksiyonu ile elde edilir (32).

$$NET = \sum_{i=1}^n w_i x_i + w_0 \quad (32)$$

$n$ , nörona gelen toplam girdi sayısını ifade eder. Toplama fonksiyonu her zaman (32)'deki gibi olmayabilir. NET girdi; ağırlıklandırılmış girişlerin çarpımı, maksimum değeri, minimum değeri, çoğunluk değeri veya kümülatif toplamı hesaplanarak çeşitli toplama fonksiyonlarıyla da elde edilebilir [47]. Hangi toplama fonksiyonun kullanılması gerektiğiyle ilgili bir kural yoktur. Genellikle ağ eğitilirken deneme yanılma yoluyla belirlenir [47]. Toplama fonksiyonu sonucu elde edilen NET değeri daha sonra doğrusal

olmayan (genellikle) aktivasyon fonksiyonundan geçirilerek nöronun çıkış değeri üretilmiş olur. Farklı aktivasyon fonksiyonları vardır bunlardan 6 tanesi Şekil 23’de gösterilmiştir.



Şekil 23. Bazı aktivasyon(transfer) fonksiyonları

1) Doğrusal aktivasyon fonksiyonu: Aktivasyon fonksiyonuna gelen ağırlıklandırılmış giriş değerleri toplamını doğrudan nöronun çıkışına aktarır.

2) Basamak aktivasyon fonksiyonu: Ağırlıklandırılmış giriş değerleri toplamını (NET) (33)’deki işlemde geçirerek nöron çıkışını üretir.

$$f(\text{NET}) = \begin{cases} 0, & \text{NET} < 0 \\ 1, & \text{NET} \geq 0 \end{cases} \quad (33)$$

3) İşaret aktivasyon fonksiyonu: Basamak aktivasyon fonksiyonuna benzer şekilde (34)’deki eşitliğe göre nöron çıkışını üretir.

$$f(\text{NET}) = \begin{cases} 1, & \text{NET} \geq 0 \\ -1, & \text{NET} < 0 \end{cases} \quad (34)$$

4) Sigmoid aktivasyon fonksiyonu: YSA'da yaygın kullanımı olan bu fonksiyon özellikle doğrusal olmayan problemlerin çözümlerinde kullanılır. Fonksiyon eşitliği (35)'de verilmiştir. Burada  $\beta$  fonksiyonun diklik parametresidir ve çıkışı iki asimptotik değer arasında sınırlar [48]. Bu sınırlama, nöronun çıkış değerini uygun bir dinamik aralıkta tutmak için oldukça kullanışlıdır [48].

$$f(\text{NET}) = \frac{1}{1 + e^{-\beta \text{NET}}} \quad (35)$$

5) Hiperbolik tanjant aktivasyon fonksiyonu: Ağırlıklandırılmış giriş değerleri toplamının tanjant fonksiyonundan geçirilmesiyle nöron çıktısı üretilir. Bu fonksiyon hiperbolik sinüs ve kosinüs fonksiyonları arasındaki oran olarak tanımlanır [49]. YSA'da yaygın kullanımı olan bir diğer aktivasyon fonksiyonudur. Fonksiyon eşitliği (36)'da verilmiştir.

$$f(\text{NET}) = \frac{\sinh(\text{NET})}{\cosh(\text{NET})} = \frac{e^{\text{NET}} - e^{-\text{NET}}}{e^{\text{NET}} + e^{-\text{NET}}} \quad (36)$$

6) Gaussian aktivasyon fonksiyonu: Fonksiyon çan şeklindedir. (37)'de fonksiyonun eşitliği verilmiştir. Burada  $\sigma$  fonksiyonun genişliğiyle ilgili bir parametredir.

$$f(\text{NET}) = e^{-\frac{\text{NET}^2}{2\sigma^2}} \quad (37)$$

### 1.7.1.2. Çok Katmanlı Yapay Sinir Ağları (ÇKYSA)

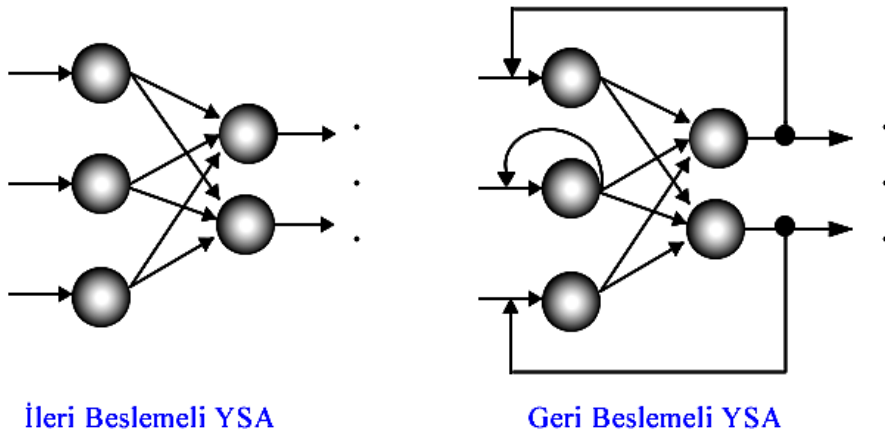
Şekil 21'de çok katmanlı yapay sinir ağı modeli gösterilmiştir. Çok katmanlı bir yapay sinir ağı; girdi katmanı, ara katman(lar) ve çıktı katmanı olmak üzere 3 temel katmandan oluşur. Girişler, girdi katmanından alınarak ara katmandaki yapay sinir hücrelerine dağıtılır. Bir ÇKYSA'da birden fazla ara katman bulunabilir. Ara katmanda işlem gören girdiler çıkış olarak çıktı katmanına aktarılır ve sonuç üretilmiş olur. ÇKYSA'nın çalışma modeli en temel de bu şekildedir. Ayrıca ÇKYSA, öğrenmeyi danışmanlı öğrenme yöntemiyle gerçekleştirir. Beklenen çıktı değeri ile üretilen çıktı

değeri farkını (hata) en aza indirmeye çalışır. Bunu da hatayı tüm ağa yayarak gerçekleştirir.

Doğrusal olan problemlerde tek katmanlı yapay sinir ağı modeli kullanılırken doğrusal olmayan problemlerin çözümünde çok katmanlı yapay sinir ağı modeli kullanılır. Bu çalışmada çok katmanlı yapay sinir ağı modeli kullanılmıştır. Bu modelin dışında; Doğrusal Vektör Parçalama Modeli (LVQ), Adaptif Rezonans Teorisi Modeli (ART), Elman Ağı Modeli, Hopfield Ağı Modeli, Counterpropagation Ağı Modeli, Cognitron Ağı Modeli, SOM (kendi kendini organize eden) Ağı Modeli, Olasılıksal Ağlar (PNN) ve Radyal Temelli Ağlar gibi kullanılan farklı ağ modelleri de vardır [47].

### 1.7.1.3. İleri Beslemeli ve Geri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında, bir katmanda bulunan nöronların çıkışları buldukları katmandan sonraki katmanda bulunan nöronlara giriş olarak uygulanırlar. Her katman için bu durum geçerlidir. Geri beslemeli yapay sinir ağları ise bir katmanda bulunan nöronların çıkışı; bulunduğu katmandan sonraki katmana ait nöronlara, kendinden önceki katmanda bulunan nöronlara ve kendi katmanındaki nöronlara giriş olarak uygulanır. Geri beslemeli YSA'da gecikmeler vardır. Şekil 24'te hem ileri beslemeli hem de geri beslemeli yapay sinir ağları beraber gösterilmiştir.



Şekil 24. İleri beslemeli ve geri beslemeli yapay sinir ağları

#### 1.7.1.4. Yapay Sinir Ağlarında Öğrenme Yöntemleri

Öğrenme yöntemlerine göre YSA; danışmanlı öğrenme (öğretmenli öğrenme), danışmansız öğrenme ve destekleyici öğrenme olarak üçe ayrılabilir. Danışmansız öğrenmede ağa giriş değerleri verilerek problemin çözümü ağdan istenir [50]. Danışmanlı öğrenmede ağın eğitimi aşamasında girişine eğitim örnekleri verilirken bu örneklerle karşılık çıkışta üretilmesi gereken değerlerde ağa verilir. Giriş ve çıkış bilgisini alan ağ, çeşitli tekrarlarla hesaplama yaparak (ağırlıkları güncelleyerek) bu girdilere karşılık hangi çıktıyı üretmesi gerektiğini öğrenir. Destekleyici öğrenme ise temelde danışmanlı öğrenmeye benzer. Fakat bu yöntemde girişlere karşılık gelen çıkış değerleri doğrudan ağa verilmez. Bunun yerine girişlere karşılık üretilen çıkışlar iyi ya da kötü şeklinde bir kriterle göre değerlendirilerek öğrenme sağlanır. Bu öğrenme yöntemlerinin bazılarını bir arada kullanan yapay sinir ağları da vardır.

#### 1.7.1.5. Yapay Sinir Ağlarında Öğrenme Algoritmaları

YSA'da öğrenme ağırlıkların güncelleştirilmesi işlemidir. Bu işlem için birçok öğrenme algoritması geliştirilmiştir. Bu algoritmalar bazı öğrenme kurallarından esinlenerek oluşturulmuştur [51]. Bu kurallar Hebb, Delta, Kohonen ve Hopfield kurallarıdır. Bu kuralları genel anlamda açıklayacak olursak;

Hebb öğrenme kuralı: Bir nöron başka bir nörondan girdi alıyorsa ve bu iki nöron aynı anda aktifse (matematiksel olarak aynı işareti taşıyorlarsa) aralarındaki ağırlık değeri artırılır, tersi durumda ise bu değer azaltılması ilkesine dayanır [51]. En eski öğrenme kurallarından biri olan Hebb kuralı diğer birçok öğrenme kurallarının da temelini oluşturur.

Delta öğrenme kuralı: Nöronun gerçek çıkışı ile istenilen çıkışı arasındaki farkı azaltmak için bağlantı ağırlık değerlerinin sürekli güncellenmesi prensibine dayanır [51]. Bu kural, bazı hatanın azaltılmaya çalışılmasından dolayı En Küçük Kareler Kuralı (Least Mean Square Rule) olarak da adlandırılır.

Kohonen öğrenme kuralı: Ağdaki nöronlar öğrenmek için (ağırlıkların güncellenmesi) birbirleriyle yarışır [51]. Yarışı kazanan nöronun ağırlığı

güncellenir[51]. Hedef çıkışa ihtiyaç duymadığı için danışmansız öğrenme ile öğrenir [51]. Yarışı kazanan nöron komşu nöronların ağırlıklarının değiştirilmesine de izin verme yetkisine sahiptir.

Hopfield öğrenme kuralı: Girdi ve çıktı nöronlarının her ikisi de aktifse veya her ikisi de aktif değilse bağlantıyı sağlayan ağırlık öğrenme katsayısı (0 ile 1 aralığında) kadar artırılır, tersi durumda ise azaltılır [51].

#### 1.7.1.5.1. Geri Yayılım Algoritması

Genelleştirilmiş delta algoritması olarak da adlandırılır. Geri yayılım algoritması ileri beslemeli ve çok katmanlı YSA'da uygulanır.  $i$ . nöronun çıkış değeri ( $\zeta_i$ ) ile  $i$ . nöronun beklenen değeri ( $B_i$ ) arasındaki fark, hatadır. Çıkıştaki bu hatayı azaltmak için hata geriye doğru yayılarak nöronlar arası ağırlıklar değiştirilir ve bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanındaki  $i$ . nöron için elde edilen hata ( $E_i$ ) (38)'de verilmiştir.

$$E_i = B_i - \zeta_i \quad (38)$$

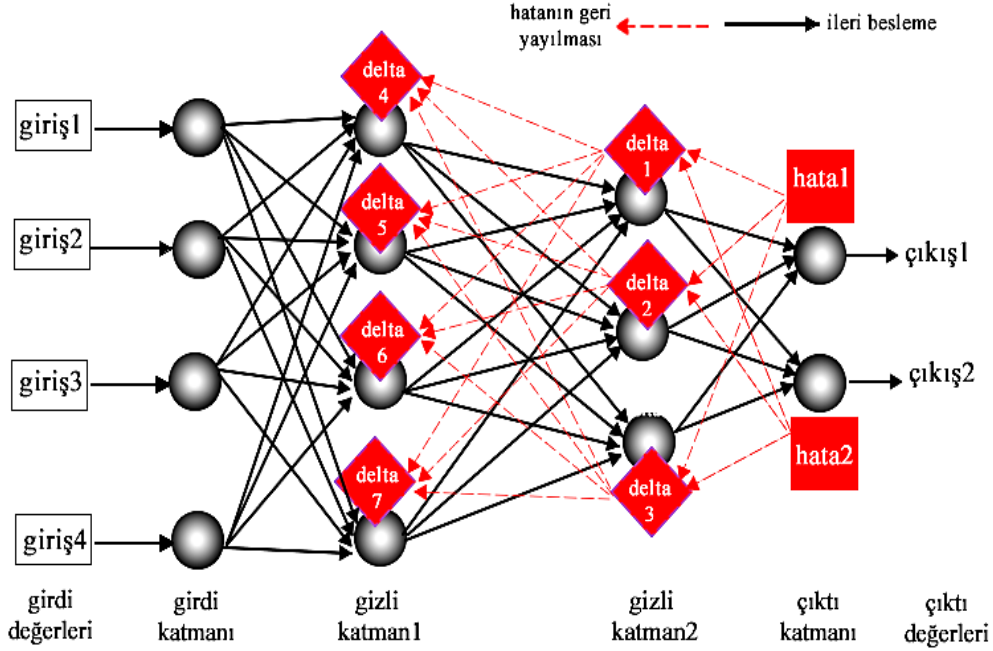
Çıktı katmanında, bütün nöronların hatalarının toplanmasıyla elde edilecek hata ise toplam hatadır. Bazı hataların negatif bazılarının pozitif olabileceğinden dolayı toplam hatanın sıfır çıkmaması için ağırlıkların kareleri alınarak toplam karesel hata bulunur (39).

$$\text{Toplam Hata} = \frac{1}{2} \sum_i E_i^2 \quad (39)$$

Çıktı katmanındaki bir nöronun toplam karesel hatasını minimum yapabilmek için hatanın, bu nörona bir önceki katmandan gelen bağlantılara dağıtılması gerekmektedir [47]. Hatanın dağıtılması (ağırlıkların değiştirilmesi) iki aşamada gerçekleşir. Birinci aşamada çıktı katmanıyla ara katman(lar)ın arasında yer alan ağırlıkların değiştirilmesi, ikinci aşamada ise ara katman ile katmanlar arası veya ara katman ile girdi katmanı



arasındaki ağırlıkların değiştirilmesi işlemleridir [47]. Şekil 25'te ÇKYSA'nın çıkışında oluşan hatanın geri yayılımı gösterilmiştir.



Şekil 25. Hatanın geri yayılması

Ara katman ile çıktı katmanındaki ağırlıkların değiştirilmesi (1. aşama) şu şekilde gerçekleşir. Ara katmanda bulunan  $j$ . nöronu çıktı katmanındaki  $m$ . nörona bağlayan ağırlığın değişim miktarı  $\Delta D^a$  olarak alınırsa  $t$ . iterasyonda ağırlığın değişim miktarı (40)'tan elde edilir [47].

$$\Delta D_{jm}^a(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta D_{jm}^a(t-1) \quad (40)$$

(40)'ta  $\lambda$  öğrenme katsayısı ve  $\alpha$  ise momentum katsayısıdır. Öğrenme katsayısı ağırlıkların bir sonraki iterasyonda hangi miktarda değiştirileceğini belirten bir değerdir. Ağ eğitimi esnasında problemin çözümü için en iyi değere ulaşmaya çalışır. Fakat her zaman bu değere ulaşması mümkün değildir. Bu sebeple ağ, yerel bir noktada elde ettiği en iyi değere (minimum hata) takılır ve bu noktadan daha iyi bir noktaya ulaşamaz. Ağın

yerelde ulaştığı bu minimum hata değeri, ağı eğiten kişinin belirlediği hata toleransının ( $\epsilon$ ) üzerinde bir hata değeri ise ağın takıldığı bu noktadan çıkarılması gerekir. Momentum katsayısının ağırlık değişim değerinin belirli bir oranda bir sonraki değişim miktarına eklenmesiyle, ağın yerel bir noktada takılmaması ve daha iyi sonuçlar elde etmesi sağlanır [47]. Eşitlik (40)'ta,  $\delta_m$  çıktı katmanındaki  $m$ . nöronun hata değeridir. Bu değer elde edilmesi (41)'de gösterilmiştir.  $f'$  (NET), kullanılan aktivasyon fonksiyonunun türevidir.

$$\delta_m = f'(\text{NET})E^m \quad (41)$$

(40)'ta değişim miktarı hesaplandıktan sonra  $t$ . İterasyonda elde edilen yeni değer (42)'de verilmiştir.

$$D_{jm}^a(t) = D_{jm}^a(t-1) + \Delta D_{jm}^a(t) \quad (42)$$

Bu işlemlerden sonra 1. aşama tamamlanmıştır. 2. aşama, ara katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesi işlemidir. 1. aşamada yapılan işlemlere benzer işlemler bu aşamada da gerçekleştirilir. Girdi katmanı ile ara katman arasındaki ağırlıkların değiştirilmesinde çıktı katmanındaki nöronlara da hatanın paylaşılması gerekir [47]. (43)'te ağırlıklardaki değişim miktarı hesaplanmakta ve (44)'te ise hata terimi bulunmaktadır. (45)'te hesaplanan hata değeri ile değişim miktarı bulunduğundan sonra ağırlıkların yeni değeri hesaplanmaktadır [47].

$$\Delta D_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta D_{kj}^i(t-1) \quad (43)$$

$$\delta_j^a = f'(\text{NET}) \sum_m \delta_m A_{jm}^a \quad (44)$$

$$D_{kj}^i(t) = D_{kj}^i(t-1) + \Delta D_{kj}^i(t) \quad (45)$$

## 2. YAPILAN ÇALIŞMALAR VE BULGULAR

Bu çalışmada 8 sağlıklı bireyin ön kolundan alınan yüzey EMG sinyalleri çevrim dışı (offline) işlenerek 7 farklı hareket sınıfının ayrıştırılması problemi YSA ile çözülmeye çalışılmıştır. Çalışmanın amacı, örüntü tanıma tabanlı kontrol edilebilen aktif protez tasarımı yaklaşımının klinik uygulamalarda kullanılabilirliğine katkı sağlamaktır. Ayrıca bu çalışmada elde edilen özniteliklerle ilgili bulgular, EMG sinyallerinin diğer önemli kullanım alanları olan; sağlık (gırtlak hastalıkları teşhisi, nöromusküler ve myopati hastalıklarının teşhisi), spor bilimleri ve konuşma tanımaya yönelik uygulamalara da dolaylı olarak katkı sağlayacaktır. Yapılan çalışmanın temel işlem adımları Şekil 26'da gösterilmiştir.




Şekil 26. Yapılan çalışmaların temel işlem adımları

Yapılan çalışmalar Şekil 26'da özetlendiği gibi 4 temel bölümden oluşmaktadır. İlk bölümde gönüllü katılımcılar seçilmiştir. Katılımcılardan, belirli bir protokole göre gerçekleştirilmiş oturumlar ile alınan EMG kayıtları bilgisayar ortamına aktarılmıştır. İkinci bölümde ise EMG sinyallerinin öznitelikleri çıkartılmadan önce veri setleri üzerinde sayısal filtrelerle bazı gürültü bileşenleri giderilmiştir. Temizlenen bu kayıtlar çeşitli pencere boylarına ayrılmıştır. Üçüncü bölümde zaman ve zaman frekans öznitelikleri çıkartılmıştır. Son bölümde ise çeşitli kombinasyonlarda YSA ile sınıflandırma işlemleri gerçekleştirilmiş ve sonuçlar tartışılmıştır.

## 2.1. EMG Sinyallerinin Elde Edilmesinde Kullanılan Donanımlar

Bu çalışmada EMG verilerinin elde edilmesinde ve bilgisayar ortamına aktarılmasında Delsys firmasının üretmiş olduğu Bagnoli™ Handheld EMG System deney setinin donanımları kullanılmıştır. Bu setteki donanımlar 2 adet aktif yüzey elektrotu, 1 adet ana yükselteç birimi ve 1 adet analog sayısal çeviriciden oluşmaktadır.

Tablo 5. Kullanılan aktif elektrotların teknik özellikleri

Aktif Elektrotlar	Özellik	Değeri	
	FİZİKSEL ÖZELLİKLER	Kasa boyutu	41x20x5mm
		Deriye temas eden yüzey sayısı	2
		Deriye temas eden yüzey alanı	10 x 1 mm
		Temas noktaları arası mesafe	10 mm
		Temas eden malzeme cinsi	%99.9 Gümüş
		Veriyi alabildiği alan	100 mm <sup>2</sup> (10 cm <sup>2</sup> )
		Kablo boyu	1.67 metre
	ELEKTRİKSEL ÖZELLİKLER	Ön Yükselteç kazancı	10V/V ± %1
		CMRR (ortak mod bastırma oranı 0-500 Hz)	-92 dB
		Güç Tüketimi	20 mW
		Gürültü	1.2 µV (RMS, R.T.I) (RTI= Referred to the input)

Aktif elektrotların teknik özellikleri Tablo 5’teki gibidir. Ana yükselteç ünitesinin teknik özellikleri ise Tablo 6’da verilmiştir.

Tablo 6. Ana yükselteç ünitesi teknik özellikleri

Ana Yükselteç Ünitesi	Özellik	Değeri
	Kanal Sayısı	2
	Her bir kanal için yükseltme kazançları	100,1000,10000
	Maksimum çıkış voltajı	$\pm 5$ Volt
	Kanal frekans cevabı	20 $\pm$ 5 Hz to 450 $\pm$ 50 Hz, 80 dB/decade
	Sistem Gürültüsü (R.T.I)	<1.2 $\mu$ V(rms)
	Güç ihtiyacı	9 VDC, 10mA
	Güç tüketimi	90 mW

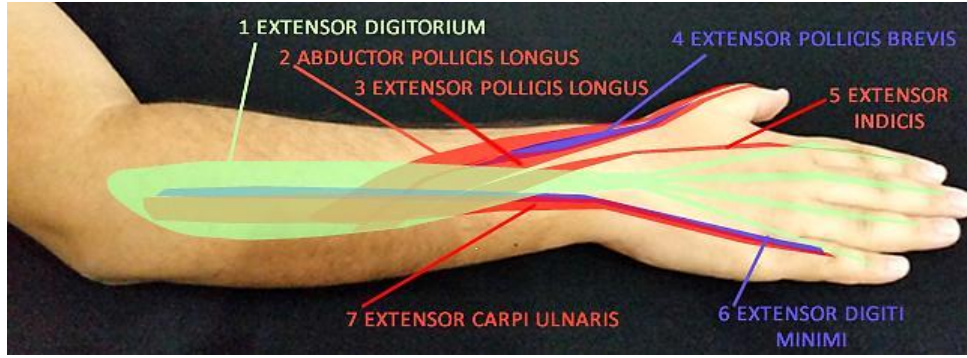
Yükseltelen sinyali sayısallaştıran ve bilgisayar ortamına aktaran analog dijital dönüştürücü özellikleri ise Tablo 7’de verilmiştir.

Tablo 7. Analog sayısal dönüştürücü kartı özellikleri

Analog sayısal dönüştürücü	Özellik	Değeri
	Çözünürlük	14 bits
	Örnekleme hızı	48 kS/s
	Voltaj aralığı	$\pm 10$ V
	Analog giriş	8

## 2.2. EMG Sinyallerinin Elde Edilmesi

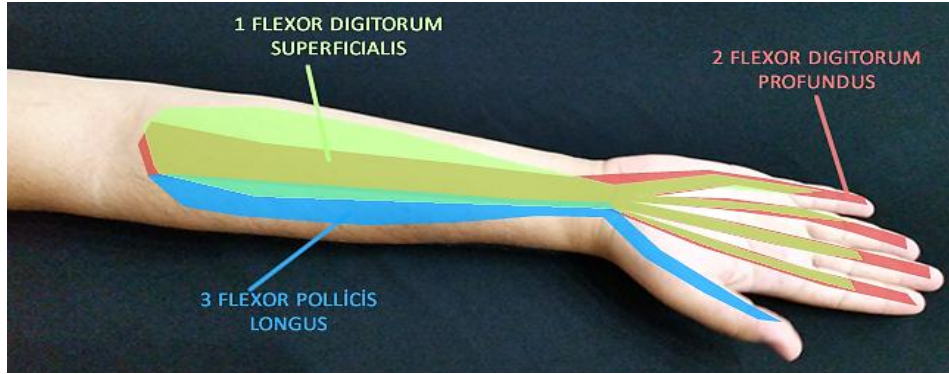
EMG verileri, gönüllü katılımcıların ön kollarında bulunan fleksör (bükücü) ve ekstensör (uzatıcı) kas grupları üzerinde deri yüzeyinden aktif elektrotlar aracılığıyla alınmıştır. Elektrotların yerleştirileceği bölge belirlenirken katılımcılardan bazı el hareketlerini (el açma/kapama) yapmaları istenmiştir. Şekil 27'deki ön kol kaslarının bulunduğu bölgeler dikkate alınmıştır. Hareketlerin yapılması esnasında bu bölgelerde gerçekleşen kasılmalara göre, el ile belirlenen yerin orta noktası en uygun yüzey EMG bölgesi seçilmiştir. Seçilen noktalara veri alımı için elektrotlar yapıştırılmıştır.



Şekil 27. EMG sinyallerinin alındığı ekstensör kas grubu

Şekil 27'de gösterildiği gibi aslında ön kol iskelet kaslarımız kemik üzerine katmanlı bir şekilde yerleşmiştir. Burada bilinmesi gereken yüzey elektrotlarıyla elde edilen verinin sadece bir kastan alınmadığıdır. Örneğin baş parmağımızın sadece germe hareketini (avcumuz yere bakarken baş parmağımızı kendimize doğru çekme) gerçekleştirirken Şekil 27'deki ekstensör (uzatıcı) kas gruplarından 1, 2, 3 ve 4 numaralı kasların görev aldığı görülebilir. Bu çalışmada 2 kanallı EMG yükselteç kullanıldığı için her gönüllü denek üzerinde aktif elektrotların yerleştirileceği 2 nokta yukarıda belirtilen yöntemle tespit edilmiştir. Şekil 27'de gösterilen ekstensör digitorium kasının bulunduğu bölgenin merkezi kanal2'nin verilerini sağlayacak bölge olacaktır.

Kanal1'in verilerini sağlayacak bölge ise aynı şekilde ön kolumuza ait fleksör kas grubudur. Fleksör kas grubu Şekil 28'de gösterilmiştir. Fleksör digitorum superficialis kasının bulunduğu bölgenin merkezi kanal1'in EMG verilerini sağlar.



Şekil 28. EMG sinyallerinin alındığı fleksör kas grubu

EMG verilerinin alınacağı bölgeler belirlendikten sonra bu çalışmada kullanılacak veriler için gönüllü katılımcılar belirlenmiştir. Biri bayan toplam 8 katılımcıya öncelikle çalışmanın amacı anlatılmıştır. Daha sonra katılımcılara verilerin ne şekilde alınacağı, bu işlemin yaklaşık ne kadar süreceği, verilerin gizliliği, elektrotların ve cihazın kendileri için herhangi bir risk içerip içermediğiyle ilgili bilgi verilmiştir. Bu çalışmaya gönüllü katılan 8 kişiye Ek 2’de verilen form doldurtulmuş ve imza altına alınmıştır. Katılımcılara ait bazı bilgiler Tablo 8’de verilmiştir. Katılımcıların vücut ağırlıklarına göre dağılımı heterojen olup, yaş ortalamaları ise 24’tür.

Tablo 8. Katılımcılara ait bazı bilgiler

Katılımcı No	Verinin Alındığı Kol	Cinsiyeti	Yaşı	Vücut Kitle Endeksi	Sınıflandırma
D1	Sağ Kol	Kadın	30	20,4	Normal Kilolu
D2	Sol Kol	Erkek	20	30,5	Obez
D3	Sol Kol	Erkek	29	32,4	Obez
D4	Sağ Kol	Erkek	30	23,2	Normal Kilolu
D5	Sağ Kol	Erkek	27	25,1	Aşırı Kilolu
D6	Sağ Kol	Erkek	19	27,7	Aşırı Kilolu
D7	Sağ Kol	Erkek	18	26,1	Aşırı Kilolu
D8	Sağ Kol	Erkek	19	22,1	Normal Kilolu

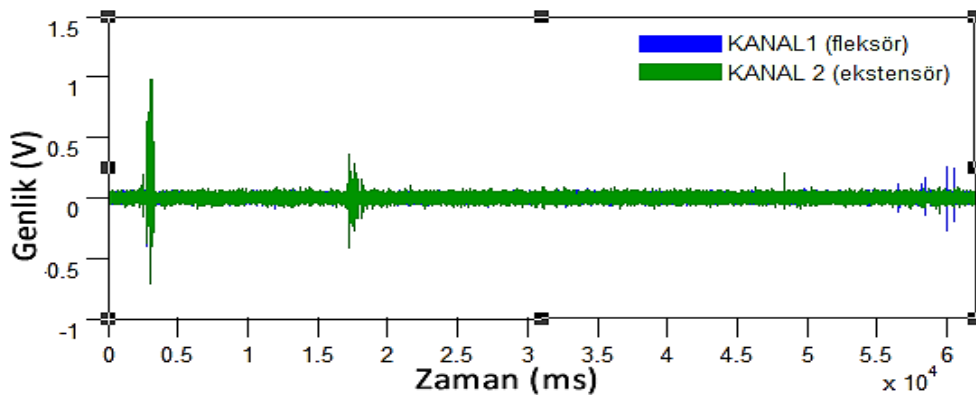
### 2.2.1. Kayıtlar Alınırken Uygulanan Protokol

Kayıtlar alınırken her bir denek için aynı protokol uygulanmıştır. Her bir katılımcıdan kayıtların alınmasına geçmeden önce; antiseptik sprey ile hem aktif elektrotlar hem de katılımcıların ön kolları temizlenmiştir. Ayrıca her bir katılımcı için kullan-at özellikte referans elektrot tercih edilmiştir. Veri alınmasına başlanmadan önce aktif elektrotlar vücuda temas ettiği bölgeye sabitlenmiştir. Elektrotları sabitleyebilmek için temizlendikten sonra üzerlerine çift taraflı yapışkan özellikte etiket yapıştırılmıştır (Şekil 29).



Şekil 29. Deri yüzeyine elektrotları sabitleyen yapışkanlı etiket


Her bir katılımcıdan alınan veriler serbest sınıfı için tek oturumda, diğer 6 hareket sınıfı için 5 oturumda gerçekleştirilmiştir. Tablo 9’da serbest sınıfı gösterilmiş ve bu sınıfa ait oturum bilgisi verilmiştir. Şekil 30’da ise 4 numaralı katılımcıdan alınan serbest sınıfa ait EMG verilerinin iki kanaldan elde edilen 60 saniye süreli bir oturum kaydı gösterilmiştir.



Şekil 30. Serbest hareket sınıfına ait oturum kaydı







Tablo 9. Serbest sınıfı ve oturumlarda uygulanan protokol

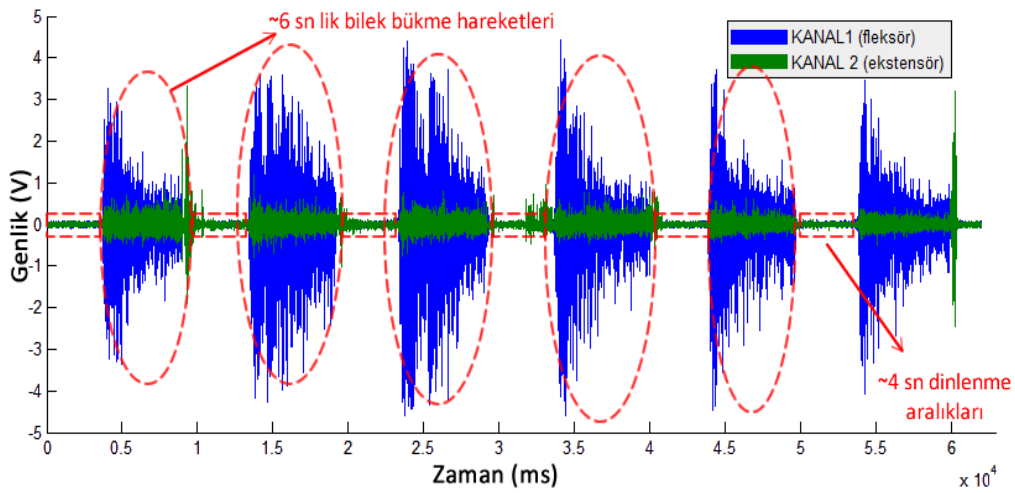
Hareket Sınıfı ve Gösterimi	Her bir oturumda uygulanan protokol
Serbest (sb) Sınıfı 	Katılımcılar oturur vaziyette ve kolları yere dik pozisyonda toplam 60 saniyeden oluşan fleksör ve ektensör kaslarından alınan kayıttır.

Diğer hareket sınıfları olan bilek bükme (bb), bilek germe (bg), el açma (ea), el kapama (ek), ön kol içeri (öi) ve ön kol dışarı (öd) hareketleri için bir oturumda uzun süreli veri alımı kasların yorulmasına sebep olacaktır. Kasların yorulması elde edilen örüntüleri değiştireceği için bu hareketler oturum kaydı sırasında dinlenme aralıkları eklenerek yaptırılmıştır.

Tablo 10. Altı hareket sınıfı ve bu sınıfların oturumlarında uygulanan protokol

					
Bilek Bükme (bb)	Bilek germe (bg)	El açma (ea)	El kapama (ek)	Ön kol İçeri (öi)	Ön kol dışarı (öd)
<b>Her Bir Oturumda Uygulanan Protokol</b>					
Katılımcılar oturur vaziyette ve kolları yere dik bir konumda hareketleri gerçekleştirmişlerdir.					
(6 saniye hareket 4 saniye dinlenme) x 6 Tekrar = 60 saniye EMG verisi					

Tablo 10’da gösterilen hareket sınıflarında kullanılan oturma bilgisine örnek olarak katılımcı 1’den (D1) alınan bilek bükme (bb) hareketine ait 3. oturma kaydı Şekil 31’de gösterilmiştir. Burada dikdörtgen içine alınmış alanlar dinlenme anlarını, büyük çember ile gösterilen alanlar ise hareket sınıfının gerçekleştiği anları göstermektedir. Mavi renkte olan işaretler fleksör kasına, yeşil renkte gösterilenler ise ekstensör kasına ait kasılma anlarının eş zamanlı alınan kayıtlarını göstermektedir.



Şekil 31. Bilek bükme hareket sınıfına ait oturma kaydı

Oturum sırasında her ne kadar dinlenme aralıkları olsa da belirtilen 6 hareket sınıfının (bb, bg, ea, ek, öi, öd) her biri 5 oturma alınacağı için aynı kasın 5 dakika boyunca çalıştırılması kasın yorulmasına neden olabilir. Bu sebeple her bir hareket sınıfına ait 5 oturma peş peşe değil 2 aşamada gerçekleştirilmiştir.

Oturumlar için uygulanan protokol Tablo 11 ve Tablo 12’de verilmiştir. 1. aşama sonunda 15 oturma kaydı alınmış ve bu aşama sonunda katılımcılar 5-10 dakika arasında değişen sürelerde dinlendirilmiştir. 2. aşama sonunda ise kalan 16 oturma kaydı tamamlanmıştır.

Her bir hareket sınıfının 5 oturumlu ve 2 ayrı aşamada gerçekleştirilmesi sırasında katılımcılardan sürekli geri bildirimler alınarak kas yorgunlukları öğrenilmiş, geri bildirimlere göre bazı durumlarda ek dinlenme süreleri de bu oturumlar arasına ilave

edilmiştir. 1. ve 2. aşamalar arasında katılımcıların ön koluna yapıştırılan elektrotlar çıkartılmamıştır.

Tablo 11. Oturumlar arası uygulanan protokol (1.aşama)

	Sırası	Gerçekleştirilen Oturumlar	Açıklama
1. aşamada alınan oturum kayıtları	1	2 bilek bükme oturumu	Her bir oturum tamamlandığında 1 dakika dinlenme
	2	2 bilek germe oturumu	
	3	3 el kapama oturumu	
	4	3 el açma oturumu	
	5	2 ön kol içeri oturumu	
	6	2 ön kol dışarı oturumu	
	7	1 serbest oturumu	
	1. aşama sonunda 5-10 dakika dinlenme		

Tablo 12. Oturumlar arası uygulanan protokol (2.aşama)

	Sırası	Gerçekleştirilen Oturumlar	Açıklama
2. aşamada alınan oturum kayıtları	1	3 bilek bükme oturumu	Her bir oturum tamamlandığında 1 dakika dinlenme
	2	3 bilek germe oturumu	
	3	2 el kapama oturumu	
	4	2 el açma oturumu	
	5	3 ön kol içeri oturumu	
	6	3 ön kol dışarı oturumu	

Tablo 11 ve Tablo 12’de belirtilen oturumlar tamamlandığında elde edilen her bir hareket sınıfının EMG verilerine ait toplam süreler ve toplam tekrar sayısı Tablo 13’de verilmiştir.

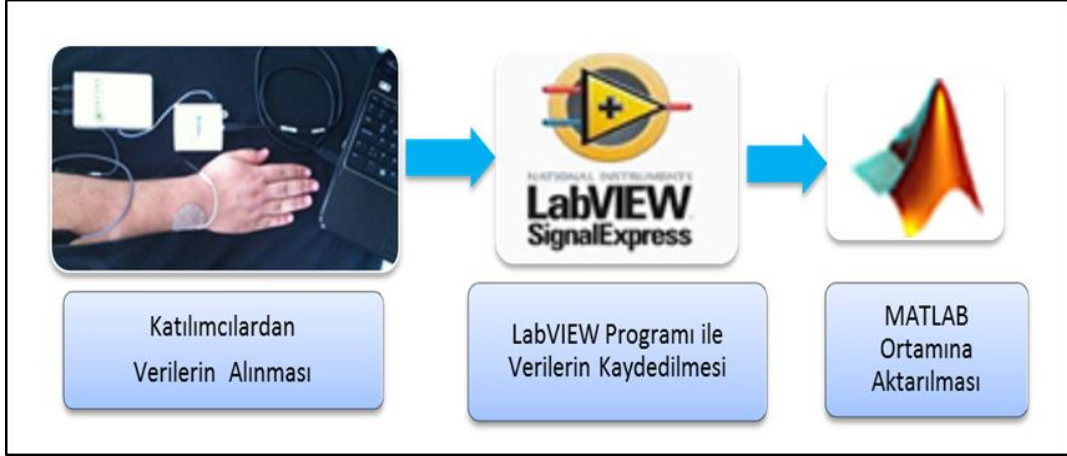
Tablo 13. Her bir sınıfa ait toplam süreler ve toplam tekrar sayısı

<b>Hareket Sınıfı</b>	<b>Her bir katılımcıdan alınan tekrar sayısı (oturum sayısı) X (oturumlardaki tekrar)</b>	<b>Tüm katılımcılardan alınan tekrar sayısı (tekrar sayısı) X (katılımcı sayısı)</b>	<b>Sınıfa ait verinin toplam uzunluğu (saniye)</b>
Bilek bükme	5x6= 30	30x8= 240	240x5 sn= 1200sn
Bilek germe	5x6=30	30x8= 240	240x5sn= 1200sn
El açma	5x6= 30	30x8= 240	240x5sn= 1200sn
El kapama	5x6=30	30x8= 240	240x5sn= 1200sn
Ön kol içeri	5x6= 30	30x8= 240	240x5sn= 1200sn
Ön kol dışarı	5x6=30	30x8= 240	240x5sn= 1200sn
Serbest	1x1= 1	1x8=8	8x60=4800sn

### 2.2.2. Sayısal Ortama Aktarma ve Kayıt

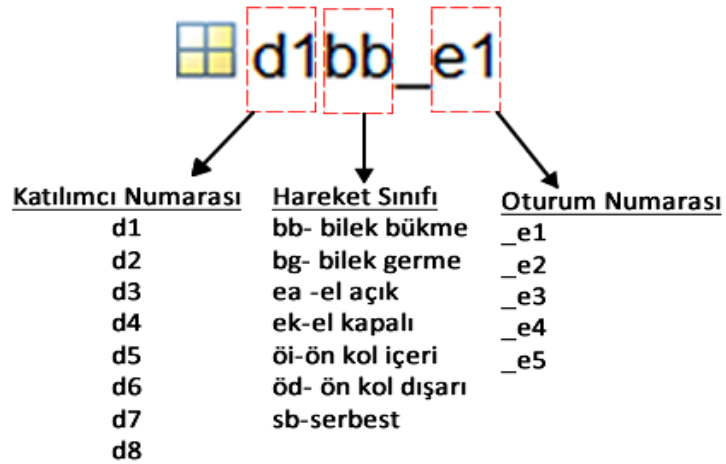
Bilgisayar ile bağlantı USB 6009 (National Instruments-NI) ADC kartının USB portuyla gerçekleştirilmiştir. USB 6009 kartı ile sayısallaştırılan ve 1 kHz örnekleme frekansı ile bilgisayar ortamına aktarılan EMG verilerinin izlenmesi ve kaydedilebilmesi için NI firmasının LabVIEW Signal Express programı kullanılmıştır. Daha sonra

kaydedilen her bir oturum kaydı işlenmek üzere MATLAB programına aktarılmıştır. Şekil 32’de kayıtların sayısal ortama aktarımı sırasında yapılan işlemler gösterilmiştir.



Şekil 32. Oturum kayıtlarının bilgisayar ortamına aktarılması

LabVIEW Signal Express programında elde edilen kayıtlara ait dosyalar sayısal ortamda işlenirken daha kolay ve yapısal programlanabilmesi için belirli bir protokolle isimlendirilmiş ve MATLAB ortamına bu yeni isimler kullanılarak aktarılmıştır. Uygulanan dosya isimlendirme protokolü Şekil 33’te gösterilmiştir.




Şekil 33. Dosya isimlendirmeleri için kullanılan protokol

### 2.3. EMG Sinyallerinin Ön İşlemlerden Geçirilmesi

EMG sinyallerinin öz nitelikleri çıkartılmadan önce bazı ön işlemlerden geçirilmesi gerekmektedir. Bu çalışmada ön işleme adımları olarak sırasıyla gürültü giderme, kalıcı durum sinyallerini seçme ve pencereleme işlemleri gerçekleştirilmiştir.

#### 2.3.1. Sayısal Filtreler ile Gürültü Giderme

Bu çalışmada Bölüm 1.5.1’de açıklanan geleneksel gürültü giderme işlemleri uygulanmıştır. Elde edilen tüm setler önce 6.dereceden 10 - 450 Hz band geçiren Butterworth sayısal filtreden geçirilmiştir. Daha sonra bütün setlere, 50 Hz şebeke gürültüsünü kaldırmak için 5. dereceden 49-52 Hz band durduran Butterworth sayısal filtre uygulanmıştır. Şekil 34’te D1 katılımcısının bilek bükme hareketi 1.oturumuna (d1bb\_e1) ait elde edilen asıl veri ve bu verinin sayısal filtrelerden geçirilmiş durumlarının Fourier dönüşümü sonuçları verilmiştir.




Şekil 34. EMG sinyallerinin sayısal filtrelerden geçirilmesi

Şekil 34’te gösterilen 50 Hz şebeke gürültüsüne bütün verilerde rastlanmıştır. Bunun sebebi kullanılan ana yükselteç ünitesinin sadece 60 Hz gürültüyü bastırmasıdır [52].

### 2.3.2. Kalıcı Durum Sinyallerinin Seçilmesi ve Bitişik Pencereleme

Her bir oturumda gerçekleşen 6 saniyelik kasılma ve 4 saniyelik dinlenme verilerinin 6 tekrarıyla oluşan kayıt setinin üzerinde hareket sınıfına ait 1 saniyelik kasılmanın başladığı bölüm ve 4 saniyelik dinlenme bölümleri çıkartılmıştır. Böylece 60 saniyelik 1 oturum verisinden sadece 30 saniyelik kalıcı durum EMG verilerini içeren yeni setler oluşturulmuştur. Şekil 35’de kalıcı durum EMG sinyallerinin seçilmesi gösterilmiştir.



Şekil 35. Kalıcı durum EMG sinyallerinin seçilmesi

Pencereleme yöntemi olarak gerçek zamanlı bir çalışma yapılmadığı için bitişik pencereleme yöntemi seçilmiştir. Pencere boyu olarak zaman düzlemi öznitelikleri için 100 ms, 150 ms, 250 ms ve 400 ms'lik farklı pencere boylarının sınıflandırma başarısı üzerinde etkisi incelenmiş olup sonuçlar Bölüm 3'te verilmiştir. Zaman - frekans düzlemi öznitelikleri ve öznitelik türlerinin birleşiminde ise 250 milisaniyelik pencere boyları kullanılmıştır.

#### 2.4. Özniteliklerin Çıkartılması

Zaman ve Zaman-Frekans düzlemi özniteliklerinin farklı kombinasyonları birleştirilerek farklı sayıda hareket sınıfı üzerinde sınıflandırma başarıları araştırılmıştır. Özniteliklerle ilgili değerlendirmeler Şekil 36'da gösterildiği gibi 4 farklı grupta incelenmiştir.



Şekil 36. Kullanılan öznitelik grupları

Öznitelikler Şekil 37'deki akış şemasında gösterildiği gibi önce tüm oturum kayıtları dosyalardan okunmuş ve bir matriste birleştirilmiştir (EK3). Daha sonra seçilen hareket sınıflarına ait istenilen öznitelikler çıkartılarak sonuçlar bir matris içinde toplanmıştır.





## **2.5. Bazı Özniteliklerin Eşik Değeri Parametrelerinin Belirlenmesi**

Zaman düzlemi özniteliklerinden sıfır geçiş tespit sayısı (SGTS), eğim gösterge değişikliği (EGD) ve Willison genliği öznitelikleri elde edilirken gürültü bileşenlerinin etkisini azaltmak için eşik değeri kullanılır. Literatürde belirtilen özniteliklerin eşik değerleri parametreleri farklılık göstermektedir. Çünkü sinyalin yükseltilmesi, sayısallaştırılması ve filtrelenmesi gibi parametreler birçok çalışmada farklı olmaktadır.

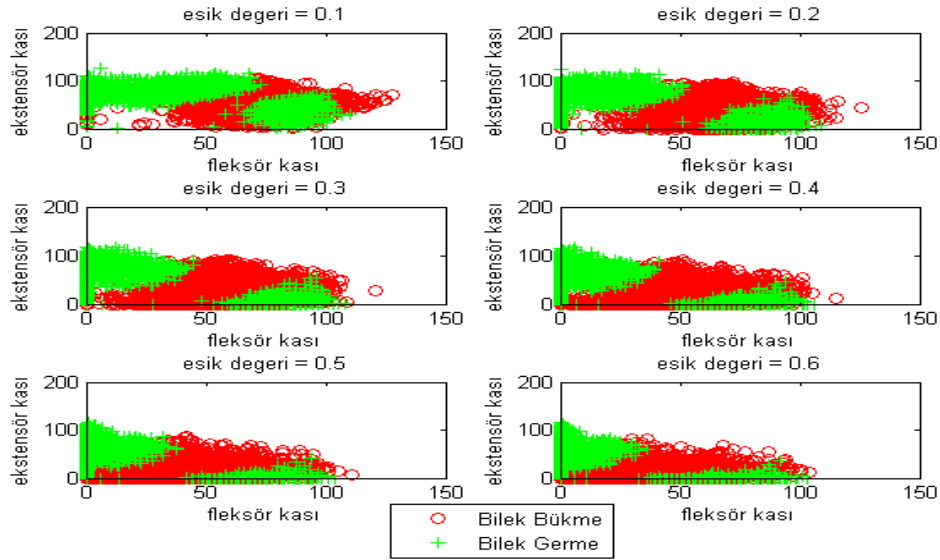
Bu çalışmada sınıflandırma işlemlerine geçmeden önce belirtilen özniteliklerin en iyi eşik değeri parametreleri belirlenmiştir. Bu amaçla, öncelikle bilek bükme ve bilek germe hareketlerinin kanal1 ve kanal2'den çıkartılan özniteliklerinin çeşitli eşik parametrelerinde saçılım grafikleri incelenmiştir. Daha sonra sadece parametre değeri belirlenmek istenen öznitelik kullanılarak bilek bükme ve bilek germe hareket sınıfları yine çeşitli eşik parametrelerinde YSA ile sınıflandırılmıştır. Bu işlemler sonucunda elde edilen sınıflandırma başarıları ve incelenen saçılım grafiklerine göre ilgili öznitelik için en uygun parametreye karar verilmiştir.

### **2.5.1. Sıfır Geçiş Tespit Sayısı (SGTS) Özniteliği Eşik Değerinin Belirlenmesi**

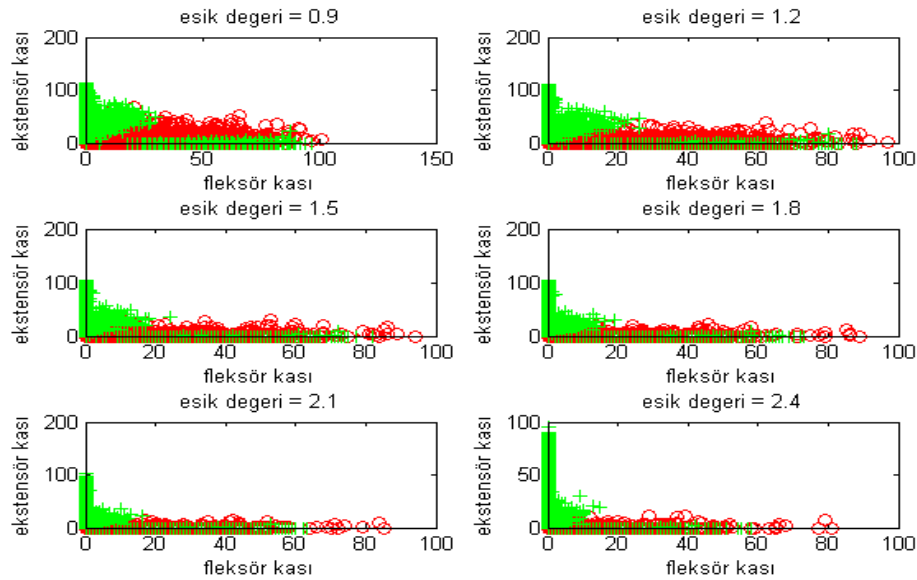
SGTS için eşik parametre değeri 0,1 ile 0,6 arasında olan saçılım grafikleri Şekil 38'de ve eşik parametre değeri 0,9 ile 2,4 arasında olan saçılım grafikleri ise Şekil 39'da gösterilmiştir.

Tüm katılımcılara ait bilek bükme ve bilek germe veri setlerinden SGTS özniteliği 250 ms'lik pencereler ile çıkartılmıştır. Bu işlem sonucu oluşan 9600 değer içinden rastgele seçilen 1000 örnek ile yapay sinir ağı peş peşe 20 kez eğitilmiş en iyi sonucu veren ağ seçilmiştir. Test için kullanılan verilerde aynı şekilde 1000 örnek rastgele seçilmiş (eğitim verilerinin tekrar seçilmemesi sağlanmıştır) ve eğitilen ağda test edilmiş sonuçlar Şekil 40'ta gösterilmiştir. Şekil 38, Şekil 39 ve Şekil 40'ta elde edilen bulgular değerlendirildiğinde SGTS özniteliği için uygun eşik değeri 0,5 olarak belirlenmiştir.


SGTS için uygulanan sınıflandırma yöntemi diğer öznitelikler olan Eğim gösterge değişikliği (EGD) ve Willison genliği özniteliklerinin sınıflandırılmasında da uygulanmıştır.



Şekil 38. SGTS özniteliğine ait 0,1 – 0,6 aralığı eşik değerlerinde saçılım grafiği




Şekil 39. SGTS özniteliğine ait 0,9 – 2,4 aralığı eşik değerlerinde saçılım grafiği




Şekil 40. SGTS özneteliği çeşitli eşik değerlerinde sınıflandırma sonuçları

### 2.5.2. Willision Genliği (WG) Özneteliği Eşik Değerinin Belirlenmesi


Kullanmış olduğumuz zaman düzlemi öznetelikleri içerisinde eşik parametresi içeren WG özneteliğine ait saçılım grafikleri Şekil 41 ve Şekil 42’de gösterilmiştir.



Şekil 41. WG özneteliğine ait 0,1–0,6 aralığı eşik değerlerinde saçılım grafiği



Şekil 42. WG özneliğine ait 0.1 – 6.6 aralığı eşik değerlerinde saçılım grafiği

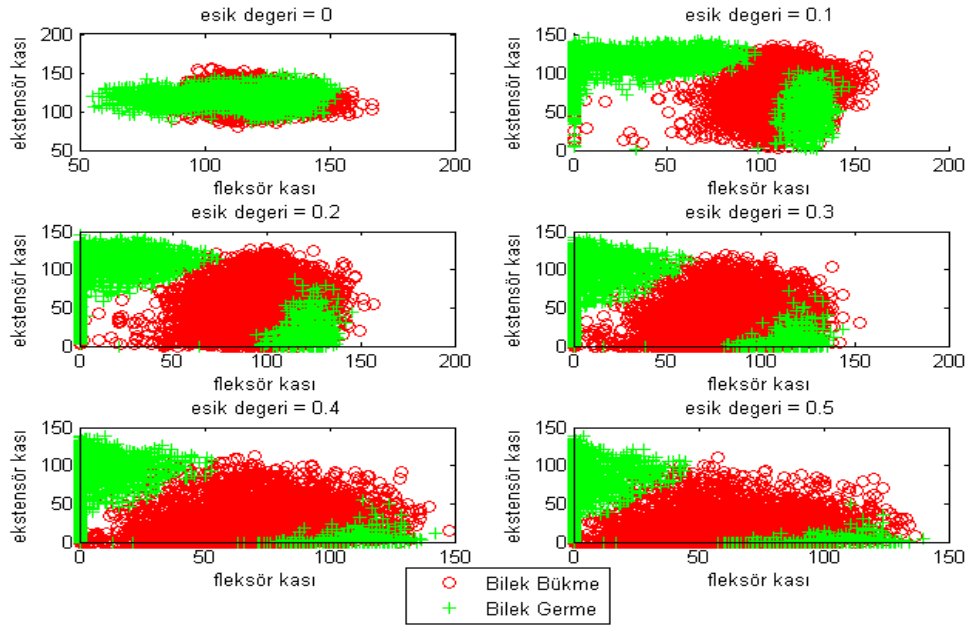


Şekil 43. WG özneliği çeşitli eşik değerlerinde sınıflandırma sonuçları


Şekil 41, Şekil 42 ve Şekil 43'te elde edilen bulgular değerlendirildiğinde Willison Genliği özneliği için uygun eşik değeri 0,2 olarak belirlenmiştir.

### 2.5.3. Eğim Gösterge Değişikliği (EGD) Özniteliği Eşik Değerinin Belirlenmesi

EGD için bir önceki öznitelikte (SGTS) olduğu gibi eşik parametre değeri 0,1 ile 0,5 arasında olan saçılım grafikleri Şekil 44’te, eşik parametre değeri 0,7 ile 1,2 arasında olan saçılım grafikleri ise Şekil 45’te gösterilmiştir.




Şekil 44. EGD özniteliğine ait 0,1-0,5 aralığı eşik değerlerinde saçılım grafiği



Şekil 45. EGD özniteliğine ait 0,7-1,2 aralığı eşik değerlerinde saçılım grafiği

EGD özniteliğinin Şekil 44 ve Şekil 45’te gösterilen eşik parametre değerlerinde gerçekleştirilen sınıflandırma sonucu ise Şekil 46’da gösterilmiştir.



Şekil 46. EGD özniteliği çeşitli eşik değerlerinde sınıflandırma sonuçları

Şekil 44, Şekil 45 ve Şekil 46’da elde edilen bulgular değerlendirildiğinde SGTS özniteliği için uygun eşik değeri 0,3 olarak belirlenmiştir.

Willison Genliği, Eğitim Gösterge Değişikliği ve Sıfır Geçiş Tespit Sayısı öznitelikleri için bulunan sonuçlar Tablo 14’te verilmiştir.

Tablo 14. Bazı öznitelikler için bulunan en iyi eşik değerleri

Öznitelik Adı	Bulunan En İyi Eşik Değeri
Willison Genliği	0,2
Eğitim Gösterge Değişikliği	0,3
Sıfır Geçiş Tespit Sayısı	0,5

## 2.6. EMG Verilerinin Sınıflandırılması

Öznitelik çıkartma aşamasından sonraki adım sınıflandırma bir diğer adıyla karar verme aşamasıdır. Bu adımda karşılaşılan özniteliklerin yedi temel sınıftan hangisine ait olduğuna karar verilmiştir. Bu çalışmada sınıflandırma işlemi için ileri beslemeli geri yayımlı sinir ağı kullanılmıştır. Değişik hareket ve öznitelik sayılarına göre farklı ağlar eğitilmiştir. Dolayısıyla giriş sayısı değişmektedir. Bununla beraber ağlardaki ara ve çıkış katmanlarının yapısı ve seçilen taşıma işlevleri birbirinin aynısıdır.

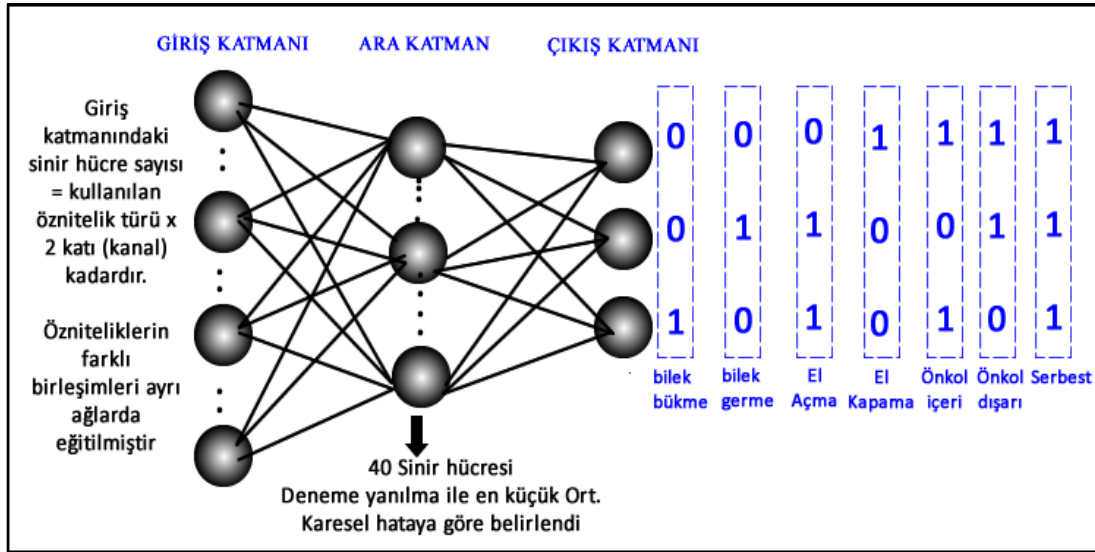
Geliştirilen her bir ağ üç katmandan meydana gelmektedir. Birinci katman olan giriş katmanında kullanılan öznitelik sayısının müsaade ettiği kadar yapay sinir hücresi mevcuttur. Gizli ya da bir diğer adıyla ara katmanda kırk, çıkış katmanında ise üç yapay sinir hücresi vardır. Ara katmandaki yapay sinir hücresi sayısı deneme yanılma yöntemiyle en küçük ortalama karesel hataya göre belirlenmiştir. Belirlenen gizli katman sinir hücre sayısı için eğitilen ağın test verilerinde de aynı başarıyı gösterip göstermediği de kontrol edilmiştir. Çıkış katmanında her bir sınıf 1'den 7'ye kadar sayılarla işaretlenmiş ve sınıflar bu sayıların 2'li karşılıklarıyla ifade edilmiştir. Şekil 47'de yapay sinir ağlarının topolojik yapısı gösterilmiştir. Hareket sınıflarının ikili karşılıkları ise Tablo 15'te verilmiştir.

Tablo 15. Hareket sınıflarının ikili olarak kodlanması

Hareket Sınıfı	İkili Karşılığı
Bilek bükme	001
Bilek germe	010
El açma	011
El kapama	100
Ön kol içeri	101
Ön kol dışarı	110
Serbest	111



Ağın eğitimi ve testi için kullanılacak bütün veriler [0, 1] aralığında normalleştirilmiştir. Geliştirilen her ağda taşıma işlevi olarak ara katmanda hiperbolik tanjant, çıkış katmanında ise doğrusal işlevler seçilmiştir. Ağların öğrenme oranı sabiti 0,01 ve momentum sabiti ise 0,90 olarak belirlenmiştir.



Şekil 47. Yapay sinir ağının topolojik yapısı

### 2.6.1. Öznitelik Matrisi ve Örneklerin Ağa Sunulması

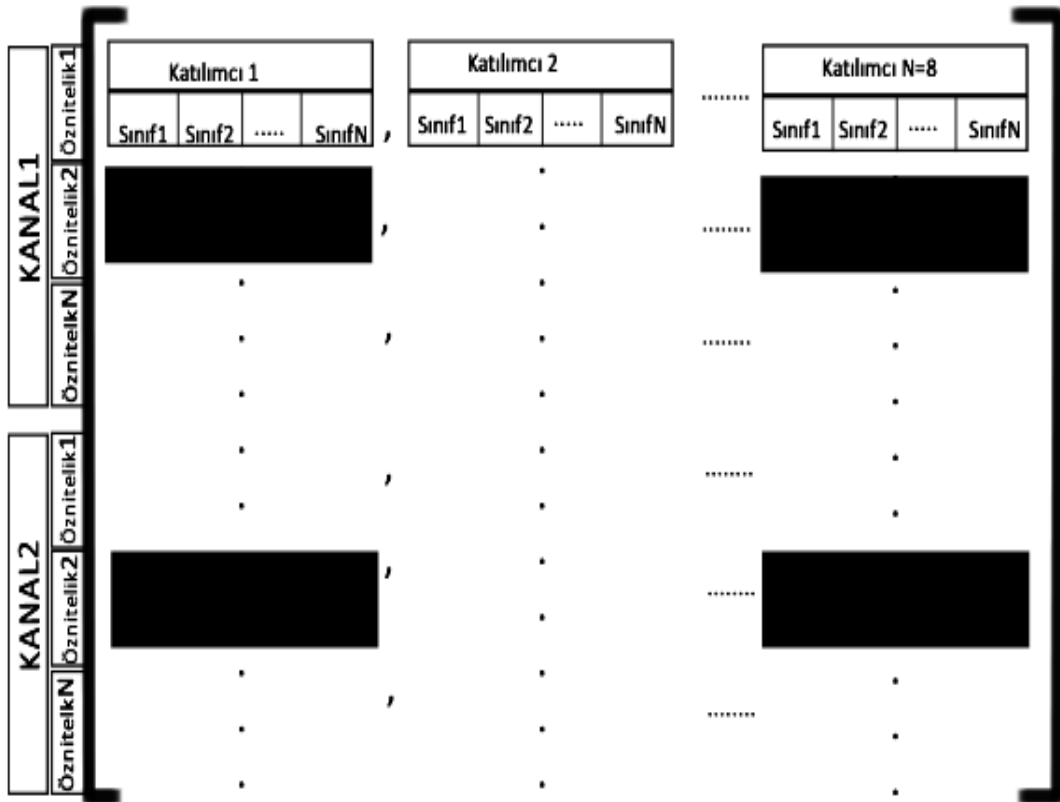
Öznitelik matrisi her satırda bir öznitelik olacak şekilde ve seçilen sınıfların yan yana (sütunlara) yerleştirilmesiyle oluşturulmuştur. Satırlarda önce kanal1'e ait tüm öznitelikler yerleştirilmiş daha sonra bu öznitelik satırlarının altına aynı sırada kanal2'ye ait öznitelikler ilave edilmiştir. Öznitelik matrisi Şekil 48'de gösterilmiştir.

Sınıflandırması yapılacak hareketlere ait çıkartılan öznitelikler Şekil 48'de gösterilen öznitelik matrisini oluşturur. Bu matris Şekil 37'deki akış diyagramında gösterilen girdiler adlı matristir. Girdiler matrisinde bulunan toplam örnek sayısı (sütunlar) belirlenen sınıf sayısı ve uygulanacak pencere boyuna göre değişiklik göstermiştir.

Ağın eğitiminde kullanılacak örnekler tüm oturum kayıtlarından şu şekilde seçilmiştir. 8 katılımcıdan alınan ve her bir hareket sınıfının 5 oturumundan oluşan

verilerin tamamı dikkate alınmıştır. Hangi katılımcıdan ve hangi oturum kaydından geldiğine bakılmaksızın her bir hareket sınıfı için 8 katılımcının tüm oturum kayıtlarından bir oturum kaydı miktarında veri rastgele seçilmiştir. Bu işlem bir örneğin tekrar seçilemeyeceği şekilde gerçekleştirilmiştir. Seçilen bu verilerin %70'i eğitim %30'u ise test verisi olarak yine rastgele bölünmüş ve yapay sinir ağının eğitimi için kullanılmıştır.

Eğitilen ağın performansını sınamak için benzer şekilde tüm oturum kayıtlarından oluşan verilerden daha önce ağın eğitilmesinde kullanılmamış, hangi katılımcıdan ve hangi oturum kaydından geldiğine bakılmaksızın her bir hareket sınıfına ait aynı sayıda sınama verileri rastgele seçilmiştir. Seçilen örneklerin tekrar kullanılmaması sağlanmıştır.



Şekil 48. Sınıflandırma için ağı sunulacak olan matrisin öznitelik yerleşimi.

### **3. TARTIŞMA VE SONUÇLAR**

Bu çalışmanın amacına yönelik olarak öncelikle, farklı gruplardaki özniteliklerin çıkartılmasıyla farklı sayıda hareket sınıflarından elde ettiğimiz çeşitli örüntülerin YSA ile sınıflandırılması sonucunda elde edilen başarıları verilecektir. Daha sonra kullanılan özniteliklerle ilgili elde edilen bulgular tartışılacaktır.

#### **3.1. Zaman Düzlemi Öznitelikleri ve AR Katsayılarıyla İlgili Sonuçlar**


Bu bölümde öncelikle 1 ile 10 arasındaki tüm derecelerde AR modelleri katsayıları özniteliklerinin sınıflandırma başarıları incelenmiştir. Daha sonra sınıflandırma başarısı iyi olan 5 derecenin AR modelleri katsayılarıyla her bir zaman düzlemi özneliğinin birleşimleri kullanılarak 4 ve 7 hareket sınıfları problemlerinin çözümü için elde edilen sonuçlar verilmiştir.

Son olarak farklı pencere boylarında (150ms, 250ms ve 400ms) ve farklı hareket sınıflarında zaman düzlemi özniteliklerinin birleşimi kullanılarak elde edilen sınıflandırma başarıları verilmiştir. Ayrıca zaman düzlemi özniteliklerinin AR2 ve AR4 öznitelikleriyle ayrı ayrı birleşimlerinin kullanılmasıyla oluşan öznitelik grupları ile 7 hareket sınıfının en iyi oranda tanınmasına çalışılmıştır.

##### **3.1.1. AR Katsayıları Sınıflandırma Sonuçları**

1 - 10. derecelerden AR modellerinin her birinin ayrı ayrı kullanılmasıyla elde edilen AR katsayılarının YSA ile sınıflandırma başarıları bu bölümde incelenmiştir. AR katsayıları özniteliklerinin çıkartılmasında 250 ms'lik pencereler kullanılmıştır. 4 hareket sınıfı (bb-bilek bükme, bg-bilek germe, ea-el açma, ek-el kapama) ve 7 hareket sınıfı problemi için YSA ile sınıflandırma başarıları Şekil 49'daki grafikte gösterilmiştir.

Şekil 49 incelendiğinde AR2'den sonra artan her bir derecede, öznitelik sayısı ve hesaplama yükü artmasına rağmen sınıflandırma başarıları hemen hemen yakın sonuçlar vermiştir. Grafikte de gösterildiği gibi 1.dereceden AR modeli (AR1) katsayılarının sınıflandırma başarısı diğerlerine göre düşük çıkmıştır.




Şekil 49. 1-10. derecelerden AR modelleri katsayıları sınıflandırma sonuçları

AR5, AR6, AR7, AR8, AR9 ve AR10 katsayılarından elde edilen sonuçlara göre az sayıda öznitelik içererek yakın sonuçlar veren AR2, AR3 ve AR4 katsayılarının EMG öznitelikleri için daha uygun olduğu sonucuna varılmıştır.

### 3.1.2 AR Katsayılarının Farklı ZD Öznitelikleriyle Birleşimlerinin Sonuçları

AR2, AR3 ve AR4 katsayıları ZD öznitelikleriyle ayrı ayrı birleşimlerinin 4 ve 7 hareket sınıfı problemi için elde edilen sınıflandırma başarıları Şekil 50'de gösterilmiştir. Burada zaman düzlemi özniteliklerinin hepsinde en iyi sonuçlar AR4 katsayılarının kullanıldığı durumlarda elde edilmiştir.

Ortalama mutlak değer eğimi (OMDE) özniteliği ve AR katsayılarının birleşimiyle oluşturulan öznitelik grubunun sınıflandırma başarıları diğer zaman düzlemi öznitelikleriyle karşılaştırıldığında düşük çıkmıştır. Şekil 50'de yer verilmeyen diğer AR katsayılarının (AR5,AR6,...,AR10)'da OMDE özniteliğiyle birleşimlerinin sınıflandırma başarıları denenmiş, bu katsayılar da benzer sonuçlar alınmıştır.



Şekil 50. AR katsayılarının farklı ZD öznitelikleriyle ayrı ayrı birleşimi sonuçları

### 3.1.3. Zaman Düzlemi Öznitelikleri ve ZD+AR Katsayılarıyla İlgili Sonuçlar

Bu bölümde verilecek zaman düzlemi (ZD) öznitelikleri, ortalama mutlak değer, ortalama mutlak değer eğimi, sıfır geçiş tespit sayısı ve Willison genliği özniteliklerinin birleşiminden oluşmaktadır. Farklı pencere boyları kullanılarak elde edilen sınıflandırma başarıları da verilmiştir. ZD özniteliklerinin birleşimine AR2 ve AR4 katsayıları da eklenerek sınıflandırma başarıları artırılmaya çalışılmıştır.

Şekil 50’de sınıflandırma başarıları düşük çıkan OMDE özniteliği ZD öznitelikleri grubundan çıkartılıp yerine dalga boyu (DB) özniteliği eklendiğinde AR2 ve AR4 katsayıları birleşimi sonuçlarında sınıflandırma başarıları bir miktar artmıştır. Fakat dikkate değer başarı artışı sağlanmadığı için burada bu sonuçlara yer verilmemiştir.

Tablo 16, Tablo 17 ve Tablo 18 incelendiğinde aşağıdaki sonuçlar elde edilmiştir.

- Pencere boylarının artırılmasıyla genellikle sınıflandırma başarısı artmaktadır. Bu çalışmada başarı artmamıştır. Bitişik pencere kullanılması, özel pencere fonksiyonu kullanılmaması ve boyut azaltması yapılmamasının buna sebep olduğu düşünülmektedir.
- AR katsayılarının ZD öznitelikleriyle kullanılmasının bütün durumlarda sınıflandırma başarısını iyi oranda artırdığı görülmektedir.
- Bu çalışmada kalıcı durum sinyalleri kullanıldığı için AR katsayılarının geçici durum sinyallerinde de iyi oranda başarıyı artırıp artırmayacağı test edilmemiştir.
- 2 Kanaldan alınan ZD özniteliklerinin iki ve dört hareket sınıfı için yeterli ama daha fazla hareket sınıfının tanınmasında yetersiz olduğu görülmektedir.
- 4. Dereceden AR modeli katsayıları ZD öznitelikleriyle birlikte kullanıldığında amacımıza uygun bir sınıflandırma başarısı sağlamıştır.

Tablo 16. ZD özniteliklerinin farklı pencere boylarında sınıflandırma sonuçları

Öznitelikler	Sınıflar	100 ms	150 ms	250 ms	400 ms
ZD	öd-öi	E: 92,7 T: 91,3	E: 94,7 T: 93,5	E: 94,8 T: 94,2	E: 96,8 T: 96,3
ZD	bb-bg-ea-ek	E: 83,8 T: 82,5	E: 84,4 T: 82,1	E: 82,9 T: 81,1	E: 83 T: 76,5
ZD	Tüm Sınıflar	E: 82,2 T: 79,7	E: 72,2 T: 70	E: 77 T: 76,2	E: 74,7 T: 71,1

Tablo 17. ZD+AR2 özniteliklerinin farklı pencere boylarında sınıflandırma sonuçları

Öznitelikler	Sınıflar	100 ms	150 ms	250 ms	400 ms
ZD+AR2	öd-öi	E: 96,5 T: 94,65	E: 96,7 T: 95,4	E: 96,6 T: 95,7	E: 95,7 T: 94,6
ZD+AR2	bb-bg-ea-ek	E: 82,5 T: 80	E: 90 T: 89,3	E: 85,1 T: 78,3	E: 90,8 T: 89,5
ZD+AR2	Tüm sınıflar	E: 85,3 T: 85,6	E: 84,9 T: 82	E: 83,4 T: 82,5	E: 85,4 T: 83,1

Tablo 18. ZD+AR4 özniteliklerinin farklı pencere boylarında sınıflandırma sonuçları

Öznitelikler	Sınıflar	100 ms	150 ms	250 ms	400 ms
ZD+AR4	öd-öi	E: 95,8 T: 92,3	E: 95,5 T: 93,3	E: 97,4 T: 93,3	E: 98,9 T: 98,3
ZD+AR4	bb-bg-ea-ek	E: 85,8 T: 79,3	E: 92,6 T: 91,3	E: 87,6 T: 83,2	E: 93,2 T: 92,6
ZD+AR4	Tüm sınıflar	E: 84,6 T: 82,1	E: 84,7 T: 81	E: 86,9 T: 86,1	E: 84,6 T: 81,1

### 3.2. Dalgacık Katsayıları Öznitelikleriyle İlgili Sonuçlar

Dalgacık dönüşümünde ana dalgacık fonksiyonu türü olarak db4 seçilmiş, ayrışma seviyesi 4 olarak gerçekleştirilmiştir. Pencere boyunun bu özniteliklere olan etkisi

incelenmemiştir. Pencere boyu olarak sabit 250 ms'lik pencereler kullanılmıştır. Dört detay katsayısı ve 1 yaklaşım katsayısı olmak üzere her pencere için toplam 5 öznitelik çıkartılmıştır. Katsayıların OMD ( $DK_{OMD}$ ) değerinin alınması her pencereden alınan öznitelik sayısını 2'ye düşürür (1 yaklaşım katsayısı + 1 detay katsayıları ortalaması). Dalgacık katsayıları eğim gösterge değışikliđi ( $DK_{EGD}$ ) tespitinde öznitelik sayısında bir değışiklik olmaz.

Tablo 19. Dalgacık katsayıları öznitelikleriyle elde edilen sınıflandırma sonuçları

Öznitelik Grubu	Sınıflar	Başarı Oranı
$DK_{OMD}$	öd-oi	E: 91,5 T: 89,3
$DK_{EGD}$	öd-oi	E: 92,1 T: 88,2
$DK_{OMD}$	bb-bg-eç-ek	E: 80 T: 78,2
$DK_{EGD}$	bb-bg-eç-ek	E: 72 T: 70
$DK_{OMD}$	Tüm sınıflar	E: 75,1 T: 73,6
$DK_{EGD}$	Tüm sınıflar	E: 71,4 T: 68,3

Tablo 19 incelendiđinde 2 kanaldan alınan dalgacık katsayıları özniteliklerinin iki ve dört hareket sınıfı için yeterli ama daha fazla hareket sınıfının tanınmasında yetersiz olduđu görölmektedir. Ayrıca  $DK_{EGD}$  ile elde edilen öznitelik sayısı  $DK_{OMD}$  ile elde edilen öznitelik sayısından fazla olmasına rağmen başarı oranları yakın çıkmıştır.



### 3.3. ZD ve ZFD Öznitelik Gruplarının Birleşimiyle Elde Edilen Sonuçlar

ZD ve ZFD özniteliklerinin AR katsayılarıyla birleştirilmesiyle elde edilen sonuçlar Tablo 20’de verilmiştir. Dikkat çeken en önemli sonuç sadece iki kanaldan elde edilen bu öznitelik gruplarının birleştirilmesiyle 7 hareket sınıfı problemi için test verileri üzerinde elde edilen başarının % 82,5 olmasıdır.

Tablo 20. Öznitelik gruplarının birleştirilmesiyle elde edilen sınıflandırma sonuçları

Öznitelik Grubu	Sınıflar	Başarı Oranı
DKOMD + AR4	öd-öi	E: 95,5 T: 93,6
DKMOA + AR4 + ZD	öd-öi	E: 96,3 T: 94,7
DK <sub>OMD</sub>	bb-bg-eç-ek	E: 80 T: 78,2
DK <sub>EGD</sub>	bb-bg-eç-ek	E: 72 T: 70
DK <sub>OMD</sub> + AR4	bb-bg-eç-ek	E: 85,8 T: 82,6
DK <sub>OMD</sub> +AR4+ZD	bb-bg-eç-ek	E: 90,2 T: 89
DK <sub>OMD</sub> +AR4+ZD	Tüm sınıflar	E: 87,01 T: 82,5

Bu sonuçların literatürdeki benzer çalışmalarda elde edilen sonuçlar ile karşılaştırılması yapılmıştır.. Tablo 21’de Doğrusal Ayrıştırma Analizi, Destek Vektör Makinaları ve Gauss Karışım Modeli sınıflayıcıları kullanılan literatürdeki benzer çalışmaların sonuçları verilmiştir. Tablo 22’de ise sınıflayıcı olarak yapay sinir ağları kullanılan literatürdeki benzer çalışmaların sonuçları verilmiştir.

Tablo 21. Benzer çalışmalarda diğer sınıflayıcılar kullanılarak elde edilen sonuçlar

Kullanıl. Öznitelikler	Öznit. Türü Sayısı	Sınıflayıcı Türü	Sınıflandırılan Hareketler (sağlıklı denekler üzerinde)	Kanal Sayısı Ve Türü	Doğruluk Oranı (%)	Referans
Zaman Düzlemi (OMD+EGD+SGTS+OMDE+DB)	5	Doğrusal Ayırıştırma Analizi	4 hareket sınıfı( el kapalı, el açık, bilek germe, bilek bükme)	2 kanal yüzey	90	K.Englehart ve ark. [33]
				4 kanal yüzey	99	
Zaman Düzlemi (OMD+SGTS+DB+EGD)	4	Doğrusal Ayırıştırma Analizi	6 hareket sınıfı( el kapalı, el açık, bilek germe, bilek bükme,bilek içe döndürme,bilek dışa döndürme)	2 kanal yüzey	yaklaşık (78 - 90)	Levi J.Hargrove ve ark. [12]
				4 kanal yüzey	ortalama 85,5 ±6	
Zaman Düzlemi(O MD+DB+SGTS+EGD+DET(Öngörülebilirlik)	5	Gauss Karışım Modeli	10 el hareketi	5 kanal	90	Z.Ju ve ark. [55]
Taman Düzlemi (OMD+DB)	2	Destek Vektör Makinaları	10 el hareketi	5 kanal	94	Z.Ju ve ark. [55]

Tablo 22. Literatürdeki Yapay Sinir Ağları sınıflayıcısı ile alınan benzer sonuçlar

Kullanıl. Öznitelikler	Öznitelik Türü Sayısı	Sınıflayıcı Türü	Sınıflandırılan Hareketler (sağlıklı denekler üzerinde)	Kanal Sayısı Ve Türü	Doğruluk Oranı (%)	Referans
Zaman Düzlemi (OMD+RM S+Varyans+ Standart Sapma+DB+ SGTS+ EGD )	7	Yapay Sinir Ağları	4 hareket sınıfı (el aşağı, el yukarı, el sağa, el sola)	2 kanal yüzey	84,4	Md. Rezwanul Ahsan ve ark. [53]
Hızlı Fourier Dönüşümü katsayıları	-	Yapay Sinir Ağları	7 el hareketi	4 kanal yüzey	90	T.Oyama ve ark.[56]
Zaman Düzlemi (OMD+AR+ EGD) + Zaman Frekans Düzlemi (DK <sub>SGTS</sub> )	4+Dalgacık dönüşümü ayrışma seviyesi	ANFİS	6 hareket sınıfı( el kapalı, el açık, bilek sağa, bilek sola, baş parmak bükme, parmakları birleştirme)	2 kanal yüzey	92 (anfis)	M.Keherzi ve M.Jahed [54]
		Yapay Sinir Ağları			86,58 (ysa)	

### 3.4. Elde Edilen Diğer Sonuçlar

Modifiye etmiş olduğumuz Ortalama Mutlak Değer (mOMD) özniteliği işleminde alt pencerelerin genlik değişimi bilgileri toplanarak sinyalin pencereler arası genlik değişimleri daha hassas izlenmeye çalışılmıştır. Modifiye edilen bu öznitelik ile ortalama mutlak değer eğimi (OMDE) özniteliğine göre daha az sayıda öznitelik elde edilerek

başarının korunması veya artırılması amaçlanmıştır. Öznitelik için 4 bölüt parametresi kullanılmış, sınıflandırma performansında iyileşme sağlanamamıştır. Hatta kısa pencere boyutlarında %2 - %3 oranında sınıflandırma doğruluğu azalmıştır. Ayrıca sadece bu özniteliklerin ayrı ayrı iki hareket sınıfı üzerinde başarıları test edilmiştir. OMDE özniteliğiyle test verilerinin sınıflandırma başarı oranı yaklaşık % 95 çıkarken mOMD ile bu oran % 77 olmuştur.

#### 4. ÖNERİLER

Bu çalışmada EMG verilerinin alındığı katılımcıların tamamının her hangi bir uzuv kaybı yoktur. Kullanılan yöntem ve teknikler uzuv kaybı olan kişilerden alınan EMG verileri üzerinde test edilebilir. Ayrıca test verileri alınırken elektrotların yerleri kaydırılarak pratikte karşılaşılabilecek özel durumlar oluşturulmaya çalışılabilir.

Hareket sınıflarının tanınması için bu çalışmada kullanılan ayırık hareketlerin yanı sıra çoklu serbestlik derecelerinin eş zamanlı ve oransal kontrolünü sağlayabilmek için benzer yöntemlerle daha karmaşık hareket sınıfları (örneğin bilek bükülürken aynı anda elin de kapatılması hareketi gibi) üzerinde çalışmalar yapılabilir.

Örüntü tanıma tabanlı yaklaşımın en önemli dezavantajı halen ticari bir sistemde uygulanamamış olmasıdır. Bu sebeple düşük güç tüketen gelişmiş mikrodenetleyiciler üzerinde çalışabilen ve örüntüleri gerçek zamanda çıkartıp işleyen sistemler üzerinde çalışmalar yapılabilir. Bu sistemlerde karar verme işlemleri için çalışmamda sonuçlarını verdiğim zaman düzlemi öznitelikleri ile AR katsayıları özniteliklerinin birleşimleri kullanılabilir.

Farklı kanallardan aynı öznitelik gruplarının değil de her kanaldan farklı özniteliklerin çıkartılmasıyla sınıflandırma başarılarında değişiklik olup olmadığı araştırılabilir.

Ayrıca katılımcılardan veri setleri alınırken belirli zaman aralıklarında sadece sesli komutlarla hareketlerin yapılması ve dinlenmenin sağlanması yerine bu işlemler hem sesli hem de görsel komutlarla sağlanabilir. Bir animasyon programı aracılığıyla yaptırılacak olan bu hareket sınıflarına ait görsel desteğin amacı katılımcılarda görsel geri bildirimle de beyinde istemli hareket isteğinin oluşmasının sağlanmasıdır.

Bu çalışmanın, bundan sonra yüzey EMG sinyallerinin örüntü tanıma tabanlı sınıflandırılması ve aktif protezlerde kontrol amaçlı kullanılabilmesiyle ilgilenen araştırmacılara katkı sağlayacak iyi bir kaynak olmasını temenni eder, başarılar dilerim.

## 5. KAYNAKLAR

1. Konrad, P., ABC of EMG A Practical Introduction to Kinesiological Electromyography, Version 1.0, Noraxon Inc., Arizona, 2005.
2. Scott, R., N., Myoelectric Control of Prostheses and Orthoses, Bulletin of Prosthetics Research, 10, 7 (1967) 93-114.
3. Li, G., Electromyography Pattern-Recognition-Based Control of Powered Multifunctional Upper-Limb Prostheses-Advances in Applied Electromyography, Joseph Mizrahi, 6, 99-116, InTech Open Access Company, 2011.
4. McLean, L. ve Scott, R., N., The Early History of Myoelectric Control of Prosthetic Limbs (1945-1970)-Powered Upper Limb Prostheses Control Implementation and Clinical Application, Ashot Muzumdar, Springer, 2004.
5. Hargrove, L., J., Towards Clinically Robust Pattern Recognition Based Myoelectric Control, Doktora Tezi, The University of New Brunswick, In the Graduate Unit of Electrical and Computer Engineering, New Brunswick, 2008.
6. Hargrove, L., J., Scheme, E., J. ve Englehart, K., B., Myoelectric Prostheses And Targeted Reinnervation-Introduction To Neural Engineering For Motor Rehabilitation, John Anderson, First Edition, 15, 291-310, Wiley-IEEE Press, New Jersey 2013.
7. Ameri, A., Scheme, E., J., Kamavuako, E., N. ve Englehart, K., B., Real-Time, Simultaneous Myoelectric Control Using Force and Position-Based Training Paradigms, IEEE Trans. Biomed. Eng., 61, 2 (2014) 279-287.
8. Fontana, J., M., Classification Of Emg Signals To Control A Prosthetic Hand Using Time-Frequency Representations And Support Vector Machines, Doktora Tezi, The Graduate School, Louisiana Tech University, Ruston, 2010.
9. Graupe, D., Salahi, J. ve Kohn, K., H., Multifunctional Prosthesis and Orthosis Control Via Microcomputer Identification Of Temporal Pattern Differences In Single-Site Myoelectric Signals, J. Biomed. Eng., 4 (1982) 17-22.
10. Graimann, B. ve Dietl, H., Introduction To Upper Limb Prosthetics, - Introduction To Neural Engineering For Motor Rehabilitation, John Anderson, First Edition, 14, 267-290, Wiley-IEEE Press, New Jersey 2013.
11. Li, G., Schultz, A., E. ve Kuiken, T., A., Quantifying pattern recognition – Based myoelectric control of multifunctional transradial prosthesis, IEEE Trans. Neural Syst. Rehab. Eng., 18, 2 (2010) 185-192.

12. Hargrove, L., J., Scheme, E., J., Englehart, K., B. ve Hudgins, B., Multiple binary classifications via linear discriminant analysis for improved controllability of a powered prosthesis, IEEE Trans. Neural Syst. Rehabil. Eng., 18, 1 (2010) 49-57.
13. Özyener, F., Fizioloji Ders Notları-Egzersize Kas Sisteminin Yanıtı. <http://tip.uludag.edu.tr/temel-tip-bilimleri/fizyoloji/ders-notlari/cizgili-kas-kasilma-mekanizmasi.pdf> 15.04.2014.
14. De Luca, C., J., Imaging the Behavior of Motor Units by Decomposition of the EMG Signal. [http://www.delsys.com/Attachments\\_pdf/EMG%20Decomposition%20Presentation.pdf](http://www.delsys.com/Attachments_pdf/EMG%20Decomposition%20Presentation.pdf) , 16.04.2014.
15. Kamavuako, E., N., Farina, D., Yoshida, K. ve Jensen, W., Relationship between grasping force and features of single-channel intramuscular EMG signals. J Neurosci Methods, 185 (2009) 143-150.
16. Kamavuako, E., N., Scheme, E., J., Englehart, K., B. ve Hudgins, B., Global features for the estimation of discharge rate from intramuscular EMG, 6th Annual International IEEE EMBS Conference on Neural Engineering, Kasım 2013, San Diego, Bildiriler Kitabı: 182-185.
17. <http://www.biopac.com/needle-electrode-concentric-25mm-education>, 30.04.2014.
18. [http://www.tmsi.com/images/stories/PDF-files/Accessorylist\\_2013.pdf](http://www.tmsi.com/images/stories/PDF-files/Accessorylist_2013.pdf), 30.04.2014.
19. <http://www.delsys.com/products/handheld-emg/> 30.04.2014.
20. <http://www.delsys.com/product/dermatrode-reference-electrode>, 30.04.2014
21. <http://www.rehab.research.va.gov/jour/09/46/4/images/stubblefieldf01.jpg>, 30.04.2014.
22. [http://www.analog.com/static/imported-files/data\\_sheets/AD620.pdf](http://www.analog.com/static/imported-files/data_sheets/AD620.pdf), 01/05/2014.
23. Siriprayoonsak, S., Real-Time Measurement of Prehensile EMG Signals, Yüksek Lisans Tezi, San Diego State Üniversitesi, San Diego, 2005.
24. Merletti, R. ve Hermens, H. J., Electromyography Physiology, Engineering, and Noninvasive Applications, Stamatios V. Kartalopoulos, 5, 107-131, John Wiley & Sons, Inc., New Jersey 2004.
25. Basmajian, J., V., Muscles alive, their functions revealed by electromyography, Third Edition, Williams & Wilkins Company, Baltimore, 1974.

26. Zecca, M., Micera, S., Carrozza, M.,C. ve Dario, P., Control of multifunctional prosthetic hands by processing the electromyographic signal, Critical Reviews<sup>TM</sup> in Biomedical Engineering, 30, 4-6 (2002) 459-485.
27. Phinyomark, A., Limsakul, C. ve Phukpattaranont, P., A novel feature extraction for robust EMG pattern recognition, Journal Of Computing, 1, 1 (2009) 71-80.
28. Jiang, C., F. ve Kuo, S., L., A comparative study of wavelet denoising of surface electromyographic signals, 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Ağustos 2007, Lyon, Bildiriler Kitabı: 1868–1871.
29. Donoho, D., L., Denoising by soft thresholding, IEEE Trans. On Information Theory, 41, 3 (1995) 613-627.
30. Güvenç, S., A., Demir, M. ve Ulutaş., M., Detection Of Forearm Movements Using Wavelets And Adaptive Neuro-Fuzzy Inference System, IEEE International Symposium on Innovations in Intelligent Systems and Applications, Haziran 2014, Alberobello.
31. Phinyomark, A., Limsakul, C. ve Phukpattaranont, P., The Usefulness of Wavelet Transform to Reduce Noise in the SEMG Signal, EMG Methods for Evaluating Muscle and Nerve Function, Mr. Mark Schwartz, 7, 107-132, InTech, 2012.
32. Oskoei, M., A. ve Hu, H., Myoelectric control systems-A survey, Biomedical Signal Processing and Control, 2 (2007) 275-294.
33. Englehart, K., Hudgins, B. ve Parker, P., A., A wavelet-based continuous classification scheme for multifunction myoelectric control, IEEE Transactions On Biomedical Engineering, 48, 3 (2001) 302–310.
34. Englehart, K., ve Hudgins, B., A Robust, Real-Time Control Scheme for Multifunction Myoelectric Control, IEEE Transactions On Biomedical Engineering, 50, 7 (2003) 848-854.
35. Pinyomark, A., Quaine, F., Charbonnier, S., Serviène, C., Tarpin-Bernanrd, F. ve Laurilleu, Y., EMG feature evaluation for improving myoelectric pattern recognition robustness, Expert Systems With Applications, 40, 12 (2013) 4832-4840.
36. Miller, C., J., M., Real-Time Feature Extraction and Classification of Prehensile EMG Signals, Yüksek Lisans Tezi, Department of Computer Science, San Diego State University, San Diego, 2008.



37. Hudgins, B., Parker, P., A. ve Scott, R., N., A new strategy for multifunction myoelectric control, IEEE Transactions On Biomedical Engineering, 40, 1(1993) 82-94.
38. Karlık, B., Koçyiğit., Y. ve Fidan, C., B., EMG İşaretlerini Sınıflamada Kullanılan İşaret İşleme Tekniklerinin Karşılaştırılması, Signal Processing and Communications Applications Conference, Mayıs 2005, Bildiriler Kitabı: 507-509.
39. Şeker, H., Elektromiyografik İşaretlerin Bulanık Sınıflayıcılarla Sınıflandırılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1995.
40. Englehart, K., B., Signal Representation for Classification of the Transient Myoelectric Signal, Doktora Tezi, The University Of New Brunswick Department of Electrical and Computer Engineering, New Brunswick, 1998.
41. [http://zone.ni.com/reference/en-XX/help/372656B-01/lvasptconcepts/wa\\_intro/](http://zone.ni.com/reference/en-XX/help/372656B-01/lvasptconcepts/wa_intro/), 05.05.2014
42. <http://www2.ece.ohio-state.edu/~zheng/wavelet-lecture.ppt>, 07.05.2014
43. Subasi, A., Classification of EMG signals using combined features and soft computing techniques, Applied Soft Computing, 12 (2012) 2188-2198.
44. Englehart, K., Hudgins, B., Parker, P., A. ve Stevenson, M., Classification of the myoelectric signal using time-frequency based representations, Medical Engineering & Physics, 21 (1999) 431-438.
45. Hargrove, L., J., Englehart, K. ve Hudgins, B., A Comparison of Surface and Intramuscular Myoelectric Signal Classification, IEEE Transactions On Biomedical Engineering, 54, 5 (2007) 847-853.
46. Oskoei, M., A. ve Hu, H., Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb, IEEE Transactions On Biomedical Engineering, 55, 8 (2008) 1956-1965.
47. Öztemel, E., Yapay Sinir Ağları, 3. Basım, Papatya Yayıncılık, İstanbul 2012.
48. Tsoukalas, L., H. ve Uhrig, R., E., Fuzzy and Neural Approaches in Engineering, John Wiley & Sons, New York 1997.
49. Karlık, B. ve Olgac, A., V., Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks, International Journal of Artificial Intelligence And Expert Systems, 1, 4, (2010) 111-122.

50. Nabiyev, V., V., Yapay Zeka, 4. Basım, Seçkin Yayıncılık, Ankara 2012.
51. Karakuzu, C., Nöral Sistemlere Giriş Ders Notları, Bilecek Üniversitesi 2014.
52. Delsys Inc., Bagnoli-2 EMG System User's Guide, 2009.
53. Ahsan M., R., Ibrahimy, M., I. ve Khalifa O., O., Electromyography (EMG) signal based hand gesture recognition using artificial neural network (ANN), Mechatronics (ICOM), 4th International Conference On, Mayıs 2011, Bildiriler Kitabı 1-6.
54. Khezri, M. ve Jahed, M., A neuro-fuzzy inference system for sEMG based identification of hand motion commands, IEEE Trans. Ind.Electron., 58, 5 (2011) 1952-1960.
55. Ju, Z., Ouyang, G., Wilamowska-Korsak, M. ve Liu, H., Surface EMG Based Hand Manipulation Identification Via Nonlinear Feature Extraction and Classification, Sensors Journal IEEE, 13, 9 (2013) 3302 – 3311.
56. Oyama, T., Mitsukura, Y., Karungaru, S.,G., Tsuge, S. ve Fukumi, M., Wrist EMG signals identification using neural network, In 2009 35th Annual Conference of IEEE Industrial Electronics, 2009, Bildiriler Kitabı: 4286-4290.

## 6. EKLER

### Ek1 ADD katsayılarının MSE hesaplaması Matlab kodları

```
function [ snc ] = meanerr( set1,set2,set3,set4,set5,seviye,db )
waveturu= {'db1','db2','db3','db4','db5','db6','db7','db8','db9','db10'...
,'rbio1.1','rbio1.3','rbio1.5','rbio2.2','rbio2.4','rbio2.6','rbio2.8','rbio3.1','rbio3.3','rbio3
.5','rbio3.7','rbio3.9','rbio4.4','rbio5.5'
,'coif1','coif2','coif3','coif4','coif5',...
,'sym1','sym2','sym3','sym4','sym5','sym6','sym7','sym8'...
,'bior1.1','bior1.3','bior1.5','bior2.2','bior2.4','bior2.6','bior2.8','bior3.1','bior3.3','bior3
.5','bior3.7','bior3.9','bior4.4','bior5.5','bior6.8','dmey'};

tset=setbirles(set1,set2,set3,set4,set5);%tüm tekrarlar(5 tekrar) bir sette toplandı
ttop=0;
for s=1:5
    set=tset{s,1};

    mse1=zeros(length(waveturu),1);
    mse2=zeros(length(waveturu),1);
    msetop=zeros(length(waveturu),1);
    for dt=1: length(waveturu);%her sete 53 ayrı dalgacık türü ile mse sonuçları
alındı
        m=0;
        m2=0;
        N=0;
        wave = char(waveturu(dt));
        [C,L] = wavedec(set(:,1),seviye,wave);%kanal 1 için temiz sinyalin wavelet
dönüşümü yapılıyor
        [C2,L2] = wavedec(set(:,2),seviye,wave);
        cD = detcoef(C,L,(1:seviye)); % kanal 1 in detay katsayıları alındı
        cD2 = detcoef(C2,L2,(1:seviye));% kanal 2 nin detay katsayıları alındı
        setx= awgn(set(:,1),db,'measured'); % kanal 1 e belirtilen dB de gürültü
eklenerek gürültülü kanal1 elde edildi
        setx2= awgn(set(:,2),db,'measured'); % kanal 2 ye belirtilen dB de
gürültü eklenerek gürültülü kanal 2 elde edildi

        [Cx,Lx] = wavedec(setx,seviye,wave); % gürültülü sinyal için wavelet
dönüşümü yapılıyor
        [Cx2,Lx2] = wavedec(setx2,seviye,wave);

        cDx = detcoef(Cx,Lx,(1:seviye));
        cDx2 = detcoef(Cx2,Lx2,(1:seviye));% gürültülü sinyalin wavelet
detay katsayıları hesaplanıyor
```

**Ek-1'in devamı**

```

for i=1 : seviye % her seviyeye iniliyor

    N=N+ length(cD{i});
    for j=1 : length(cD{i}) % her seviyedeki normal ve gürültülü
katsayıların farkı alınarak toplam bir değer elde ediliyor

        m =m+((cD{i}(j)-cDx{i}(j))^2);
        m2=m2+((cD2{i}(j)-cDx2{i}(j))^2);
    end
end

mse1(dt)=m/N;% değerlerin ortalaması alınarak ortalama karesel hata
bulunuyor
mse2(dt)=m2/N;

msetop=(mse1+mse2)/2;%her iki kanal hataları toplamı alınıp tekrar
ortalaması alınıyor

end

ttop=ttop+msetop; % 5 tekrarın ayrı ayrı hesaplanan mse toplamları toplanarak
bunların ortalaması alınıyor

end

snc=ttop/5; % bu ortalama bir kişinin bir sınıfa ait yapmış olduğu tüm tekrarların
MSE sidir.

end

```

**Ek2 Bilgilendirme ve katılımcı onay formu****BİLGİLENDİRME VE KATILIMCI ONAY FORMU****Değerli katılımcı;**

Sizi Doç.Dr. Mustafa ULUTAŞ danışmanlığında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisi Seyit Ahmet GÜVENÇ tarafından yürütülen Elektromiyografik (EMG) sinyallerin işlenmesi ve sınıflandırılmasıyla ilgili çalışmaya katılmaya davet ediyoruz. Bu çalışmanın temel hedefi EMG örüntülerini tanıma, doğru bir şekilde sınıflandırabilme ve aktif kol protezlerinin geliştirilmesine katkı sağlamaktır.

**Emg Sinyal Ölçüm İşlemleri :**

Ölçüm işlemi için ön kolunuza ait Extensor Carpi Radialis ve Flexor Carpi Radialis kaslarının bulunduğu yerlerin deri üzerlerine 2 adet aktif yüzey elektrot yapıştırılacaktır. Aktif elektrotlar bir yükseltici üniteye bağlıdır. Yükselticiden geçirilen sinyaller sayısallaştırılıp bilgisayar ortamına taşınacak ve sinyaller araştırmanın hedefine uygun bilgisayar ortamında işlenecektir. Sizlerden 6 sınıfa ait ön kol hareketlerini her biri 1 dakikadan oluşan oturumlar ile alınacak ve bu oturumlar 5 kez tekrar edilecektir. Ölçüm işlemi toplamda yaklaşık 44 dakika sürecektir.

Eğer çalışmamıza katılmak isterseniz eğitim, bilgilendirme ve dinlenme süreleri de eklendiğinde bu araştırma için en az 3 saatinizi ayırmanız gerekebilir. İsteğiniz durumunda 2 veya 3 ayrı günde çalışmamıza katılabilirsiniz

**Yarar ve Zararları :**

Ön kol deri üzerinden yüzey elektrotlar ile veri alımı gerçekleşeceği için verinin alındığı cilt üzerinde ve vücudunuzun diğer bölgelerinde ciddi bir risk oluşturmamaktadır. Elektrotlar deri üzerine yapıştırılacağı için deri yüzeyinde minimal düzeyde tahriş gerçekleşebilir. Elektrotları yerleştirirken veya çıkartırken biraz rahatsızlık hissedebilirsiniz fakat bu size acı hissettirecek derecede olmayacaktır.

Bu işlemlerin size doğrudan bir yararı olmayacaktır. **Katılımınız tamamen isteğinize bağlıdır.**

**Ek2'nin devamı****Katılımcı Hakları:**

Bu çalışmaya katılmak zorunda değilsiniz. Eğer çalışmaya katılmayı kabul ederseniz istediğiniz zaman hiçbir gerekçe belirtmeden katılımınızdan vazgeçme hakkınız vardır.

**Gizlilik:**

Veriler sadece araştırmacılarda tutulacak ve güvenli bir yerde depolanacaktır. Bütün datalar grup etiketi ve numaralandırma ile kodlanacaktır. Kişisel bilgileriniz olarak adınız, soyadınız, yaşınız, kilonuz, boyunuz, emg veriniz ve bu verinin hangi kolunuzdan ölçüldüğü bilgileri alınacaktır. Katılımcılardan alınan bütün bilgiler kesinlikle 3.şahıslarla paylaşılmayacaktır. Ancak verilere bu çalışmaya danışmanlık yapan Doç.Dr.Mustafa ULUTAŞ, yürütücü Seyit Ahmet GÜVENÇ ve çalışmayı değerlendirecek olan jüri üyeleri erişebilir. Danışman ve Yürütücü tarafından bulgular ticarileştirilebilir veya bulgular herkese açık ortamda tartışmaya açılabilir. Katılımcıların bu çalışmanın bulgularından veya sonuçlarından haber alma hakkı vardır.

Eğer bu çalışmaya katılmayı kabul ediyorsanız lütfen aşağıdaki bölümleri doldurunuz ve imzalayınız.

Katılımcı Adı Soyadı :

İmzası :

Tarih:

Verilerinizin paylaşımını istiyor musunuz? (Evet/Hayır) Cevabınız: .....

Araştırma bulgularından haberdar olmak istiyor musunuz? (Evet/Hayır) Cevabınız :.....  
Cevabınız evet ise lütfen telefon ve mail adresinizi belirtiniz

Tel :..... Mail:.....

Katılımcı bilgilerini alan Seyit Ahmet GÜVENÇ

imzası:

Tarih:

**Ek3 Tüm oturum kayıtlarının bir matriste birleştirilmesi (MATLAB)**

```
clear all
dosyalar=dir('SETLER')

[a b]=size(dosyalar);
for i=1:a
    if isdir(dosyalar(i).name) ==0
        dnum =i
    end
end

adi=strcat('SETLER\',dosyalar(dnum).name)
load(adi);
tumsetler=load(adi); % tumsetler adlı deęişkene SETLER klasöründeki .mat
dosyasına baęlı deęişkenler yüklendi

setadlari=fieldnames(tumsetler);

[a,b]=size(setadlari);
sayac=1;

% tüm oturum kayıtlarına ait dosyaların bir matriste toplanması
for i=1:a
    set=setadlari(i);
    set=char(set);

    icerik=eval(set); %ilgili setin içerięi icerik adlı deęişkene oradan da setler adlı
    hücreye yazdırılıyor

    setler{sayac}=icerik ;% sonuçta setler=[ [30000x2],[30000x2],[30000x2],
    [30000x2], ..... [30000x2] ] şeklinde [1x248] lik bir hücrede birleştirilir
    karsiliklar{sayac}=adlaricoz(set);
    sayac=sayac+1;
end
```

#### Ek4 Hareket sınıflarına ait istenilen özneliklerin çıkartılması (MATLAB)

```

pencereboyu=250;
esikwamp = 0.20;      % wamp fonksiyonu için eşik değeri.
segmentsayisi = 4 ;  % mavslpmodify fonksiyonu için segment sayısı
derece1 = 4;        % aryule_hesabi için derece
esikzero = 0.5;    % zeroc için eşik fonksiyonu parametresi
esikssc = 0.5;     % ssc için treshold değeri
seviye=4;          % Ayrık dalgacık ayrıştırma seviyesi
waveturu='db4';    % ana dalgacık ailesi

[a,setsayisi]=size(setler);

olcu   = [1 1 1 1 1 1 1];      %herbiri bir sınıfı belirtir 1=bilek bükme, 2=bilek
germe, 3=el açma, 4=el kapama, 5=ön kol iceri, 6=ön kol dışarı, 7=serbest
denekOlcu = [1 1 1 1 1 1 1]; %8 denekten her birini isteğe göre seçebilmek için.

%öznelik no 1 2 3 4 5 6 7 8 9 10 12 14
oznelikOlcu=[0 0 0 0 0 0 1 0 0 0 0 0 0 ]

sayac = 1;
for i=1:setsayisi
    set=setler{i};
    ad=setadlari{i};      % setler=[ [30000x2],[30000x2],[30000x2], [30000x2], .....
[30000x2] ] şeklinde

    k1=setler{i}(:,1); % i.setin kanal 1 verisi
    k2=setler{i}(:,2); % i.setin kanal 2 verisi

[kanalboyu,b]=size(k1);
    penceresayisi=round(kanalboyu/pencereboyu);% toplam pencere sayısı
hesaplanıyor

    for j=1:penceresayisi% her bir pencere alınacak

        k1pencere=k1((j-1)*pencereboyu+1:j*pencereboyu); %her bir pencere kanallar
için ayrı ayrı alınıyor
        k2pencere=k2((j-1)*pencereboyu+1:j*pencereboyu);

```



**Ek4'ün devamı**

```
[kisim1,kisim2 ] = fonkcalistir(
oznitelikOlcu,k1pencere,k2pencere,esikwamp,segmentsayisi,derece1,esikzero,esikssc,
seviye,waveturu );

if( olcu(karsiliklar{i}.hareketCinsi ) == 1) % örneğin 'ea' hareketi için
karsiliklar{i}.hareketcinsi==3 ise ve olcu[3]==1 ayarlanmışsa hareket girisler
dizisine yazılır
    if(denekOlcu(str2num(karsiliklar{i}.denekNo)) == 1)
        girdiler(:,sayac) = ulacalis(kisim1, kisim2);
        ciktilar(sayac) = karsiliklar(i);
        sayac = sayac + 1 ;
    end
end

end
end
girdiler = girdiler';
```

## Ek5 Özniteliklere ait alt fonksiyonlar

```

% _____
function [ sonucmav ] = mav(set )
%mean absolute value
toplam=0;
for i=1:1:length(set),
    toplam=toplam+abs(set(i));
end
sonucmav=1/length(set) * toplam;
end
% _____

function sonucslp = mavslp(set)

setboyu=max(size(set));

    tempparca1=set(1:(setboyu/2));
    tempparca2=set(setboyu/2+1:setboyu);
    sonucslp=mav(tempparca2)-mav(tempparca1);
end

% _____
function [snc] = aryule_hes(set,derece)
% girilen verisetinin her bir kanalını yulewalker
%yönetimi ile belirlenen derecedeki AR(autoregressive) katsayılarını hesaplar
%yulewalker yöntemi hesaplaması için matlabdaki 'aryule' fonksiyonu kullanıldı.

    temp=aryule(set,derece);
    snc=temp(2:derece+1);
end
% _____
function [ snc,a ] = sscyeni(set,treshold )
snc=0;
setboyu=length(set);
a=zeros(setboyu,1);

for i=2:setboyu-1
    if ( ( ((set(i)>set(i-1)) && (set(i)>set(i+1))) || ((set(i)<set(i-1)) && (set(i)
<set(i+1))) ) && ( abs(set(i)-set(i+1)) >= treshold) || (abs(set(i)-set(i-1)) >=
treshold) ) )
        snc=snc+1;
        a(i)=set(i);
    end
end
end
end

```

**Ek5'in devamı**

```

function [snc] = wamp( set,treshold )
snc=0;
setboyu=length(set);
for i=1:setboyu-1
    if ( abs((set(i)- set(i+1)))> treshold )
        snc=snc+1;
    end
end
%_____

function [ snc ] = wavelength( set )
snc=0;
setboyu=length(set);
for i=2:setboyu
    snc= snc + (abs(set(i)-set(i-1)));
end
%_____

function [ snc,yerleri] = zerocyeni(set,treshold)
snc=0;
setboyu=length(set);

for i=1:setboyu-1
    if ( ( ( set(i)>0) && ( set(i+1)<0) ) || ( (set(i)<0) && ( set(i+1)>0) ) ) &&
(abs(set(i)-set(i+1))>treshold ))
        snc=snc+1;
        yerleri(i)=i;
    else yerleri(i)=0;
    end
end
yerleri=yerleri';
end
%_____

function sonuc = dalgacikmav( set,seviye,waveturu )

[C,L] = wavedec(set,seviye,waveturu );

sonuc=zeros(seviye+1,1);
cD = detcoef(C,L,(1:seviye));
cA = appcoef(C,L,waveturu,seviye);
temp=0;

for i=1:seviye
    sonuc(i)=mav(cD{1,i});
end
sonuc(seviye+1)=mav(cA);

```

**Ek5'in devamı**

```
function sonuc = dalgacikssc( set, seviye, waveturu, esikssc )
```

```
[C,L] = wavedec(set, seviye, waveturu );
sonuc=zeros(seviye+1,1);
cD = detcoef(C,L,(1:seviye));
cA = appcoef(C,L,waveturu,seviye);
temp=0;
```

```
for i=1:seviye
    sonuc(i)=sscyeni((cD{ 1,i}),esikssc);
end
sonuc(seviye+1)=sscyeni(cA,esikssc);
```

```
% _____
```

```
function [ snc ] = mavslpmodify( set, segmentsayisi )
parcaboyu=floor(length(set)/segmentsayisi);
tempparca=zeros(segmentsayisi,parcaboyu);
```

```
for i=1:segmentsayisi
    tempparca(i,:)=set( ((i-1)*parcaboyu+1):(i*parcaboyu));
end
```

```
snc=0;
for i=1:segmentsayisi-1
    snc=snc + mav(tempparca(i+1,:))-mav(tempparca(i,:));
end
```

```
end
% _____
```

## Ek6 Öznitelik çıkartılması için kullanılan yardımcı alt fonksiyonlar

```

function ulasnc = ulacalis(varargin)

fonksayi=nargin; % gelen fonksiyon sayısına bak
boy=0;
for i=1:fonksayi
    [a,b]=size(varargin{i});%
    boy=boy+max(a,b);% fonksiyon sayısını boy değerine ata / tek fonksiyon varsa
    boy=1
end
ulasnc=zeros(1,boy);
ulasyc=1;

for i=1:fonksayi
    fboy=max(size(varargin{i}));
    f=varargin{i};

    for j=1:fboy
        ulasnc(ulasyc)=f(j);
        ulasyc=ulasyc+1; % ulasnc[ pencere1_öznit, pencere2_öznit, pencere3_öznit,
pencere4_öznit N, .... ] şeklinde tek satır vektörü döndürür
    end
end
% _____

function [xx,yy ] = fonkcalistir(
oznitelikOlcu,k1pencere,k2pencere,esikwamp,segmentsayisi,derece1,esikzero,esikssc,se
viye,waveturu )
kont=0;
for i=1:length( oznitelikOlcu)

    if oznitelikOlcu(i)==1
        switch i
            case 1
                x1= wamp(k1pencere, esikwamp); xx= ulacalis(x1);
                x1= wamp(k2pencere, esikwamp); yy= ulacalis(x1); kont=1;
            case 2
                if(kont==1)
                    x2= mavslpmodify(k1pencere, segmentsayisi); xx = ulacalis(xx,x2);
                    x2= mavslpmodify(k2pencere, segmentsayisi); yy= ulacalis(yy,x2);
                else
                    x2= mavslpmodify(k1pencere, segmentsayisi); xx = ulacalis(x2);
                    x2= mavslpmodify(k2pencere, segmentsayisi); yy= ulacalis(x2); kont=1;
                end
            end
        end
    end
end

```

**Ek6'nin devamı**

```

case 3
  if(kont==1)
    x3= mav(k1pencere) ; xx = ulacalis(xx,x3);
    x3= mav(k2pencere) ; yy= ulacalis(yy,x3);
  else
    x3= mav(k1pencere) ; xx = ulacalis(x3);
    x3= mav(k2pencere) ; yy= ulacalis(x3); kont=1;
  end
case 4
  if(kont==1)
    x4= mavslpyeni(k1pencere); xx = ulacalis(xx,x4);
    x4= mavslpyeni(k2pencere); yy= ulacalis(yy,x4);
  else
    x4= mavslpyeni(k1pencere); xx = ulacalis(x4);
    x4= mavslpyeni(k2pencere); yy= ulacalis(x4); kont=1;
  end
case 5
  if(kont==1)
    x5= aryule_hes(k1pencere, derece1) ; xx = ulacalis(xx,x5);
    x5= aryule_hes(k2pencere, derece1) ; yy= ulacalis(yy,x5);
  else
    x5= aryule_hes(k1pencere, derece1) ; xx = ulacalis(x5);
    x5= aryule_hes(k2pencere, derece1) ; yy= ulacalis(x5); kont=1;
  end
case 6
  if(kont==1)
    x6= zerocyeni(k1pencere, esikzero); xx = ulacalis(xx,x6);
    x6= zerocyeni(k2pencere, esikzero); yy= ulacalis(yy,x6);
  else
    x6= zerocyeni(k1pencere, esikzero); xx = ulacalis(x6);
    x6= zerocyeni(k2pencere, esikzero); yy= ulacalis(x6); kont=1;
  end
case 7
  if(kont==1)
    x7= wavelength(k1pencere); xx = ulacalis(xx,x7);
    x7= wavelength(k2pencere); yy= ulacalis(yy,x7);
  else
    x7= wavelength(k1pencere); xx = ulacalis(x7);
    x7= wavelength(k2pencere); yy= ulacalis(x7); kont=1;
  end
end

```

**Ek6'nin devamı**

```
case 8
  if(kont==1)
    x8= sscyeni(k1pencere,esikssc); xx = ulacalis(xx,x8);
    x8= sscyeni(k2pencere,esikssc); yy= ulacalis(yy,x8);
  else
    x8= sscyeni(k1pencere,esikssc); xx = ulacalis(x8);
    x8= sscyeni(k2pencere,esikssc); yy= ulacalis(x8); kont=1;
  end
case 9
  if(kont==1)
    x9= dalgacikmav(k1pencere,seviye,waveturu ); xx = ulacalis(xx,x9);
    x9=dalgacikmav(k2pencere,seviye,waveturu ); yy= ulacalis(yy,x9);
  else
    x9= dalgacikmav(k1pencere,seviye,waveturu ); xx = ulacalis(x9);
    x9=dalgacikmav(k2pencere,seviye,waveturu ); yy= ulacalis(x9); kont=1;
  end

case 10
  if(kont==1)
    x10= dalgacikssc(k1pencere,seviye,waveturu,esikssc ); xx = ulacalis(xx,x10);
    x10=dalgacikssc(k2pencere,seviye,waveturu,esikssc ); yy= ulacalis(yy,x10);
  else
    x10= dalgacikssc(k1pencere,seviye,waveturu,esikssc ); xx = ulacalis(x10);
    x10=dalgacikssc(k2pencere,seviye,waveturu,esikssc ); yy= ulacalis(x10); kont=1;
  end

  otherwise

  end
end
end
end
```

## ÖZGEÇMİŞ

Seyit Ahmet GÜVENÇ 1985 yılında Samsun ili Havza ilçesinde doğdu. İlk ve orta öğrenimini Çorum'da tamamladı. 2003 yılında kazandığı Süleyman Demirel Üniversitesi Teknik Eğitim Fakültesi Bilgisayar Sistemleri Öğretmenliği Bölümü'nden 2007 yılında mezun oldu. 2007-2009 yılları arasında Süleyman Demirel Üniversitesine bağlı meslek yüksekokullarında yarı zamanlı öğretim görevlisi olarak çalıştı. 2010 ve 2011 yıllarında Trabzon ilinde Milli Eğitim Bakanlığına bağlı okullarda Teknik Öğretmen olarak çalıştı. Bu görevinden sonra Süleyman Demirel Üniversitesi/Teknik Bilimler Meslek Yüksekokulu/Bilgisayar Teknolojileri Bölümünde Öğretim Görevlisi olarak çalışmaya başladı. Halen bu görevini sürdürmektedir. Yabancı dil olarak İngilizce bilmektedir.

1. Güvenç, S., A., Demir, M. ve Ulutaş., M., Detection Of Forearm Movements Using Wavelets And Adaptive Neuro-Fuzzy Inference System, IEEE International Symposium on Innovations in Intelligent Systems and Applications, Haziran 2014, Alberobello, Italy.

2. S. A. Guvenc, M. Ulutas, M. Demir "Kol Emg Sinyallerinin Örüntü Tanıma Tabanlı Analizi ve Yapay Sinir Ağları İle Sınıflandırılması", IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2014) , Nisan 2014, Trabzon.