

**T.C.**  
**İNÖNÜ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**EMG SİNYALLERİNİN SINIFLANDIRILMASI**

**FURKAN AYAZ**

**YÜKSEK LİSANS TEZİ**  
**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**AĞUSTOS 2018**

**MALATYA**

**Tezin Bařlıđı:** EMG Sinyallerinin Sınıflandırılması

**Tezi Hazırlayan:** Furkan AYZ

**Sınav Tarihi:** 10.08.2018

Yukarıda adı geen tez jürimizce deđerlendirilerek Bilgisayar Mühendisliđi Ana Bilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

**Sınav Jüri Üyeleri**

**Tez Danıřmanı: Do. Dr. Davut HANBAY**

İnönü Üniversitesi

.....

**Dr. Öğr. Üyesi Barıř Baykant ALAGÖZ**

İnönü Üniversitesi

.....

**Dr. Öğr. Üyesi Ömer Faruk ALÇİN**

Bingöl Üniversitesi

.....

**Prof. Dr. Halil İbrahim ADIGÜZEL**

Enstitü Müdürü

## ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduđum “EMG Sinyallerinin Sınıflandırılması” başlıklı çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Furkan AYZ

# ÖZET

Yüksek Lisans Tezi

## EMG SİNYALLERİNİN SINIFLANDIRILMASI

Furkan AYZ

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

56+viii sayfa

2018

Danışman: Doç. Dr. Davut HANBAY

EMG sinyali kasların kasılmasının sonucunda oluşan elektriksel aktivasyonun ölçülmesi işlemidir. Bu nedenle kaslardan alınan EMG sinyalleri kaslar hakkında bilgi sağlamaktadır. Bu bilgiler günümüzde kas hastalıkları teşhisinde, protez kol ve hareket tespiti çalışmalarında kullanılmaktadır.

Bu tezde EMG sinyallerinden Yapay Sinir Ağları kullanılarak hareket tespiti amaçlanmıştır. Öncelikle alınan EMG sinyallerine Kısa Zamanlı Fourier Dönüşümü (KZFD) uygulanarak sinyallere ait zaman-frekans gösterimleri elde edilmiştir. Elde edilen zaman-frekans temsilinden İstatistiksel metotlar, Gri Seviye Eş-Oluşum Matrisi (GSEM) ve Yerel İkili Örüntüler (YİÖ) metotları ile EMG sinyaline ait öznitelikler çıkarılmıştır. Çıkarılan bu öznitelikler Yapay Sinir Ağlarına (YSA) giriş verisi olarak verilerek EMG sinyalleri sınıflandırılmıştır.

DeneySEL sonuçlar incelendiği zaman tasarlanan sistemin kullanılan EMG verisi üzerinde başarılı sonuç aldığı gözlemlenmiştir.

**ANAHTAR KELİMELELER:** EMG Sinyal İşleme, Kısa Zamanlı Fourier Dönüşümü, Gri Seviye Eş-Oluşum Matrisi, Yerel İkili Örüntüler, Yapay Sinir Ağları

# **ABSTRACT**

Master Thesis

## **CLASSIFICATION OF EMG SIGNALS**

Furkan AYZ

Inonu University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

56+viii pages

2018

Supervisor: Asst. Prof. Davut HANBAY

The EMG signal is the process of measuring the electrical activation that occurs as a result of muscular contraction. For this reason, EMG signals from the muscles provide information about the muscles. This information is currently used in the diagnosis of muscular diseases, prosthetic arm and motion detection studies.

In this thesis, motion detection is aimed by EMG signals using Artificial Neural Networks.

Primarily, time-frequency representations of signals are obtained by applying Short Time Fourier Transform (STFT) to the received EMG signals. From the obtained time-frequency properties, the attributes of the EMG signal were extracted with the statistical methods, Gray-Level Co-Occurrence Matrix (GLCM) and Local Binary Pattern (LBP) methods. These extracted attributes are given as input data to Artificial Neural Network (ANN) and the system performance is calculated.

When the experimental results were examined, it was observed that the designed system had a successful result on the used EMG data.

**KEYWORDS:** EMG Signal Processing, Short Time Fourier Transform, Gray Level Co-Occurrence Matrix, Local Binary Patterns, Artificial Neural Networks

## TEŐEKKÜR

Yüksek Lisans Tez çalışmamın gerçekleşmesinde, her türlü yardımı ve desteęi saęlayan ve çalışmalarımnda yardımcı olan danışman hocam Sayın Doç. Dr. Davut Hanbay'a;

Yüksek Lisans Tez çalışmasında, akademik bilgi ve önerileriyle sürekli yol göstermeye çalışan değerli hocam Sayın Öğr. Gör. Ali Arı'ya;

Yüksek Lisans Tez çalışmalarında sürekli motive eden, yol gösteren ve destek veren değerli hocalarım Dr. Öğr. Üyesi Faruk Ugranlı ve Dr. Öğr. Üyesi Ersin Alabeyoęlu'na;

Yüksek lisans Tez hazırlama sürecinde sürekli yanımda olan ve destek veren anneme, babama ve kardeşlerime

Teşekkür ederim.

## İÇİNDEKİLER

ÖZET .....	i
ABSTRACT .....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER .....	iv
SİMGELER VE KISALTMALAR.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ .....	viii
1. GİRİŞ .....	1
1.1 Literatür Taraması ve Değerlendirilmesi .....	2
1.2 Tezin Amacı .....	8
1.3 Tezin Organizasyonu .....	8
2. EMG İŞARETLERİNİN ÖLÇÜLMESİ .....	9
2.1 Sinir Sistemi .....	9
2.1.1 Nöronun Yapısı .....	9
2.1.2 Hareketin Kas Kontrolü .....	10
2.2 EMG .....	11
3. ÖZİNİTELİK ÇIKARIMI .....	14
3.1 Fourier Dönüşümü .....	14
3.1.1 Kısa Zamanlı Fourier Dönüşümü .....	18
3.2 İstatistiksel Öznelik.....	21
3.3 Yerel İkili Örüntüler (YİÖ).....	21
3.4 Gri Seviye Eş-Oluşum Matrisi (GSEM) .....	24
4. YAPAY SİNİR AĞLARI .....	28
5. UYGULAMA .....	32
5.1 Veri Seti .....	32
5.2 Yapılan Çalışma .....	33
5.2.1 EMG Sinyalinin Alınması.....	34
5.2.2 KZFD Uygulanması .....	35
5.2.3 Z-F Gösterimlerinin Bölütlenmesi .....	37
5.2.4 Öznelik Çıkarılması .....	38
5.2.5 YSA ile Sınıflandırma.....	38
5.3 Sonuçlar.....	39
6. SONUÇLAR VE DEĞERLENDİRME .....	52

7.	KAYNAKLAR .....	53
----	-----------------	----



## SİMGELER VE KISALTMALAR

EMG	Elektromiyografi
KZFD	Kısa Zamanlı Fourier Dönüşümü
GSEM	Gri Seviye Eş-Oluşum Matrisi
MÜAP	Motor Ünite Aksiyon Potansiyelleri
YİÖ	Yerel İkili Örüntüler
YSA	Yapay Sinir Ağları
MSS	Merkezi Sinir Sistemine
PSS	Periferik Sinir Sistemi
Z	Zaman
F	Frekans
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif
AR	Otoregresif

## ŞEKİLLER DİZİNİ

Şekil 2.1. Nöron Yapısı.....	10
Şekil 2.2. EMG Sinyalinin Ölçülmesi.....	12
Şekil 3.1. KZFD Görünümü.....	19
Şekil 3.2. Pencere fonksiyonları örnekleri ve frekans cevapları.....	20
Şekil 3.3. Temel YİÖ operatörü örneği.....	22
Şekil 3.4. Genişletilmiş YİÖ operatörünün örnekleri .....	23
Şekil 3.5. YİÖ(8,1) operatörünün uygulaması .....	23
Şekil 3.6. N = 5 seviyeleri ve dört farklı ofset için birlikte-oluşum matrisi üretimi..	25
Şekil 3.7. Dört GSEM matrisleri için karar füzyonu .....	25
Şekil 4.1. Yapay bir sinir ağının çalışma prensibi .....	28
Şekil 4.2. Basit yapay sinir ağı örneği .....	29
Şekil 4.3. Biyolojik ve yapay sinir ağı tasarımı .....	30
Şekil 4.4. Yapay sinir ağı modeli .....	30
Şekil 5.1. Veri setinde bulunan el hareketleri .....	32
Şekil 5.2 Önerilen Sistemin çalışma şeması .....	33
Şekil 5.3. Her bir sınıfa ait ham EMG sinyallerinin görüntüleri.....	34
Şekil 5.4. Ham Sinyallerin KZFD yöntemi ile Z-F düzlemine alınması .....	36
Şekil 5.5. Ham Sinyallerin KZFD yöntemi ile Z-F düzlemine alınması .....	37
Şekil 5.6. Z-F gösteriminin bölütlenmesi.....	38
Şekil 5.7. A-B,C,D,E,F sınıflarına ait ROC eğrisi .....	42
Şekil 5.8. B- C,D,E,F sınıflarına ait ROC eğrisi .....	44
Şekil 5.9. C-D,E,F sınıflarına ait ROC eğrisi.....	46
Şekil 5.10. D-E,F sınıflarına ait ROC eğrisi .....	47
Şekil 5.11. E,F sınıflarına ait ROC eğrisi.....	48
Şekil 5.12. Bütün sınıflara ait ROC eğrisi.....	49

## ÇİZELGELER DİZİNİ

Çizelge 1.1. Özellik Çıkarımı ile ilgili literatürde kullanılan bazı yöntemler.....	4
Çizelge 1.2. Sınıflandırma yöntemleri ile ilgili kullanılan bazı yöntemler.....	5
Çizelge 1.3. [15]'te elde edilen sonuçlar.....	7
Çizelge 5.1. İki sınıf için tasarlanan YSA modelinin özellikleri .....	40
Çizelge 5.2. A sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı .....	40
Çizelge 5.3. A sınıfı ile diğer sınıflara ait performans sonuçları .....	41
Çizelge 5.4. B sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı .....	43
Çizelge 5.5. B sınıfı ile diğer sınıflara ait performans sonuçları .....	43
Çizelge 5.6. C sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı .....	45
Çizelge 5.7. C sınıfı ile diğer sınıflara ait performans sonuçları .....	45
Çizelge 5.8. D sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı .....	46
Çizelge 5.9. D sınıfı ile diğer sınıflara ait performans sonuçları .....	47
Çizelge 5.10. D sınıfı ile F sınıfına ait sınıflandırma doğruluk başarısı .....	47
Çizelge 5.11. E sınıfı ile diğer sınıflara ait performans sonuçları.....	48
Çizelge 5.12. Altı sınıf için tasarlanan YSA modelinin özellikleri.....	49
Çizelge 5.13. Önerilen yöntemin mevcut yöntemler ile doğruluk oranlarının karşılaştırılması .....	50
Çizelge 5.14. Tüm sisteme ait Sınıflandırma Doğruluk Başarısı.....	51

## 1. GİRİŞ

İnsanların vücut yapısını, diğer canlıların vücut yapısından ayıran birçok farklı özellik vardır. Bu farkı özelliklerden birisi de insanın fizyolojik yapısının oluşturan kas yapısıdır. Kas yapısı tarih boyunca incelenmeye ve araştırılmaya çalışılmıştır. Kas yapısı ve kas çalışma sistemi üzerinde çeşitli çalışmalar yapılmıştır. Fakat tıp teknolojileri ve bilgisayar sistemlerinin gelişmesi ile kaslardan daha fazla bilgi alınıp analiz edilmesi üzerinde yapılan çalışmalarda artış görülmektedir [1].

Elektromiyografi'nin (EMG) gelişimi 1666 yılında Francesco Redi'nin elektrik balığı üzerinde yaptığı deney ile başlamaktadır. 1773 yılına gelindiğinde Walsh, Eel balıklarının kas yapısının elektriksel bir aktivasyon oluşturabileceğini göstermiştir. Galvani ise 1792 yılında yaptığı çalışmasında elektriğin kas kasılmalarını başlatabilecek etkiye sahip olduğunu göstermiştir. 1849 yılında Dubios-Raymond istemli çalışan kasların kasılması sırasında meydana gelen elektriksel aktivitenin kaydedilmesi işleminin olabileceğini bulmuştur. Elektriksel aktivitenin ilk kaydı 1890 tarihinde Marey tarafından gerçekleştirilmiş ve elektromyografi terimi literatüre girmiştir. EMG sinyallerinin alınması işlemi 1950'lere kadar sürekli gelişmiş ve araştırmacılar kaslardan daha fazla bilgi alabilmek için daha gelişmiş elektrotlar kullanmaya başlamışlardır. 1960'larda daha karmaşık hastalıkların tespiti için yüzey EMG kliniklerde kullanılmaya başlanmıştır. 1980'lerin başlarında Cram ve Steger, EMG algılama cihazı kullanarak kasların çeşitliliğini taramak için bir klinik yöntemi geliştirmişlerdir.

1980'lerin ortasına kadar elektronik elemanların üretim teknikleri ve doğrulukları seri üretimine elverişli değildi. Fakat günümüzde istenilen elektronik elemanların üretimi rahatlıkla yapılabilmektedir [2].

Günümüzde EMG sinyallerinin birçok kullanım alanı vardır. Bu kullanım alanlarından bazıları; hastanelerde kas ve sinir hastalıkları tespiti, hareket bozuklukları ve fizyoloji çalışmaları, fizik tedavi merkezleri ve protez el ve kol çalışmaları olarak sıralanabilir.

## 1.1 Literatür Taraması ve Değerlendirilmesi

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

[3] nolu çalışmada sağlıklı bireylerden, miyopati ve nöropati rahatsızlığı olan hastalardan alınan EMG sinyallerinin analiz edilmesi, YSA ile sınıflandırılması ve sistemin performansının incelenmesi amaçlanmıştır. Alınan sinyallerden dönüş analizi, küçük segment analizi ve frekans analizi yöntemleri kullanılarak özellikler çıkarılmıştır. Sınıflandırma işlemi için geliştirilmiş bir geri yayılma ağı, radyal temel ağ ve öğrenme vektörü kuantizasyon ağı kullanılarak sınıflandırma yapılmıştır. Tasarlanan sistemin %60-80 aralığında doğru sınıflandırma başarımı elde edildiği belirtilmiştir.

[4] nolu çalışmada normal sağlıklı kişilerden, miyopati ve motor nöron hastası olan kişilerden alınan EMG sinyallerinin sınıflandırılması için sinir ağı karar destek sistemi geliştirilmiştir. Alınan sinyallerden zaman alanı parametreleri, frekans alanı parametreleri, cepstral katsayıları ve 3 farklı dalgacık katsayısı (Daubechies, Chui ve Battle-Lemarie) yöntemleri ile sinyallere ait özellikler çıkarılmıştır. Çıkarılan bu özellikler çoklu öz düzenleyici harita ile sınıflandırılmış ve bulunan sonuçlar çoğunluk oyu ile belirlenmiştir. Bireysel özellik kümeleri için sınıflandırma başarımı %69.1 iken, altı sınıf sınıflandırma başarımının %76.9 olduğu görülmüştür.

[5] nolu çalışmada Motor Ünite Aksiyon Potansiyellerinin (MÜAP) iki farklı desene tanıma tekniği ile sınıflandırılması incelenmiştir. Bunlardan birincisi YSA tekniği, ikincisi ise Öklid mesafesine dayalı istatistiksel desen tanıma tekniğidir. Yapılan çalışma sonucunda normal kişilerden, miyopati ve motor nöron hastalarından alınan veriler sınıflandırıldığında YSA yönteminde %97.6 ve istatistiksel yöntemde ise %95.3 sınıflandırma başarımı elde edilmiştir.

[6] nolu çalışmada EMG sinyalinden hastalık tespiti amaçlanmıştır. Bu amaçla alınan EMG sinyallerine Hızlı Fourier Dönüşümü uygulanmıştır. Daha sonra Temel

Bileşenler Analizi kullanılarak Hızlı Fourier Dönüşümü katsayıları azaltılmış ve sistemin girişine uygun özellikler elde edilmiştir. Çıkarılan bu özellikler Destek Vektör Makineleri ile sınıflandırılarak sistemin en yüksek başarımı %85.42 olarak bulunmuştur.

[7] nolu çalışmada İleriye Dönük Hata Geri Yayılımı YSA modeli ve Dalgacık Ağları temelli sınıflandırıcılar geliştirilmiş ve EMG sinyallerinin sınıflandırılmasında ki başarımlar karşılaştırılmıştır. Alınan EMG sinyallerinden özellik çıkarmak amacıyla AR modeli kullanılmış ve buradan gelen değerler sisteme giriş verisi olarak verilmiştir. Sistemin doğruluk oranı kıyaslandığında Dalgacık Ağları modeli %90.7, İleriye Dönük Hata Geri Yayılımlı YSA modeli ise %88 başarımlar elde ettiği gözlemlenmiştir. Önerilmiş olan Dalgacık Ağları modelinin EMG sınıflandırıcı için daha etkin sonuç verdiği sonucuna varılmıştır.

[8] nolu çalışmada Nöropati ve Miyopati hastalıklarının tespiti amaçlanmıştır. Bu amaçla Tahmini Dalgalanma Analizi, Dalgacık Dönüşümü ve Hızlı Fourier dönüşümü yöntemleri ile özellik çıkarılmış ve Sinir Ağları, Bulanık Mantık ve Destek Vektör Makineleri yöntemleri de sinyal sınıflandırma işlemi yapılmıştır ve çıkan sonuçlar Çizelge 1.1 ve Çizelge 1.2’de verilmiştir.

Çizelge 1.1. Özellik Çıkarımı ile ilgili literatürde kullanılan bazı yöntemler

Yöntemler	Yıl/Yazar	Açıklama
Çift Eşik Algılama	1998, Bonato	Tek eşik olanlarla karşılaştırıldığında çift eşik için dedektörler, yüksek algılama olasılığı daha iyidir.
Dalgacık Dönüşümü	1997, Laterza ve Olmo	Çoklu çözünürlük temsil gerçekleştirmek için kullanılabilir ve çok bileşenli sinyal ile uğraşırken etkilenmez.
	1999, Pattichis	Farklı çözünürlük seviyelerinde sinyali analiz etmek için kullanılabilir.
	1998, Ismail and Asfou	Hızlı ve Kısa Zamanlı Fourier dönüşümü (HFD ve KZFD) EMG nin frekans spektrumunu belirlemek için en iyi yöntemlerdir.
WignerVille Dağılımı	1994, Davies and Reisman	Ortak yoğunluk spektrumundaki yerleştirme özelliklerini çok iyi gösterir.
	1990, Boualem and Pete	Zaman frekans uzayında yüksek çözünürlüklü sinyal karakterizasyonu ve gürültüleri yok eder.
Kısa Zamanlı Fourier dönüşümü	1994, Davies and Reisman	Kas yorgunken spektrumun sıkıştığını açıkça göstermişlerdir.

Çizelge 1.2. Sınıflandırma yöntemleri ile ilgili kullanılan bazı yöntemler

Yöntemler	Yıl/Yazar	Açıklama
Yapay Sinir Ağları (YSA)	2002, Wang and Buchana	YSA modeli EMG sinyalleri arasındaki ilişkiyi temsil etmek için kullanılabilir.
	1994, Del and Park	Diğer yöntemler tarafından kolayca bulunamayan verileri bulmak mümkündür. Aynı zamanda gerçek zamanlı miyoelektrik sinyali tam olarak tanıyabilir.
Dalgacık Sinir Ağı	2006, A.Subasi, M. Yılmaz and H.R.Ozcalik	Dalgacık ve sinir ağları sisteminin karakteristiğinden oluşan bu tanımlama iyi sonuçlar verir.
Bulanık Mantık	F.H.YCha	Bulanık mantık sistemleri insan kararına benzer ve verideki çelişkiler tolere edilebilir

[9] nolu çalışmada EMG sinyallerinde hastalık tespiti amaçlanmıştır. Alınan EMG sinyallerinden özellik çıkarmak amacıyla Temel Bileşenler Analizi yöntemi kullanılmış ve çıkarılan bu özellikler Olasılıksal Sinir Ağı ile sınıflandırılmıştır. Yapılan sınıflandırma sonucunda sistemin ortalama sınıflandırma oranı %91.72 olarak tespit edilmiştir.

[10] nolu çalışmada MÜAP'ın morfolojisini tanımlamak için farklı özellik yöntemleri araştırılmıştır. Çok Katmanlı Algılayıcı Sinir Ağları, Dinamik Bulanık Sinir Ağı ve Uyarlamalı Nöro-Bulanık Çıkarım Sistemi sınıflandırıcıları kullanılarak, EMG sinyallerinin sınıflandırılmasında doğruluk oranları karşılaştırılmıştır. Uyarlamalı Nöro-Bulanık Çıkarım Sisteminin daha yüksek tanıma oranı, ve daha yüksek güvenilirlik noktalarında diğer yöntemlerden daha avantajlı olduğu gözlemlenmiştir.

[11] nolu çalışmada EMG sinyallerinden hastalık tespiti doğruluğunu arttırmak amacıyla Parçacık Sürü Optimizasyonu (PSO) ve Destek Vektör Makinelerini (DVM) hibritleşiren yeni bir PSO-DVM modeli önerilmiştir. Bu amaçla öncelikle sinyalleri Ayrık Dalgacık Dönüşümü uygulanmıştır. Dalgacık dönüşümü ile alt bantlara ayrıştırılan EMG sinyallerini temsil etmek için bu alt bantlardan istatistiksel özellikler



çıkarılmıştır. Daha sonra yapılan sınıflandırma işlemi sonucunda önerilen yöntemin %97.41 doğruluk oranı ile en iyi sonucu verdiği gözlemlenmiştir.

[12] nolu çalışmada ön koldan alınan EMG sinyallerinin sınıflandırılması amaçlanmıştır. Bu nedenle 21 gün boyunca tekrar ederek 4 kanaldan kaydedilen EMG verilerini kullanarak kol hareketi tespiti için 50 tane zaman ve frekans düzlemi davranışları incelenmiştir. Her bir özellik ilk başta tek tek Lineer Diskriminant Analiz ile sınıflandırılmıştır. Daha sonra çoklu öznitelikler ile sınıflandırma yapmak amaçlanmıştır. Tekli sınıflandırmada Örnek Entropi yöntemi ile elde edilen öznitelikler Lineer Diskriminant Analiz ile sınıflandırıldığında %93.37 ile en iyi performansı verdiği gözlemlenmiştir. Daha sonra öznitelik sayısı artırarak sınıflandırmalar yapılmıştır. Öznitelik sayısı 4'e (Örnek Entropi, Cepstral katsayısı, Kök kare ortalama ve Dalga boyu uzunluğu ) çıkarıldığında ise doğruluk oranı %98.87'e çıktığı belirlenmiştir.

[13] nolu çalışmada EMG sinyallerinden nörolojik kas hastalıklarının tespiti için EMG sinyallerinden MÜAP ve Otoregresif (AR) modeli ile öznitelik çıkartılmıştır. Çıkarılan bu öznitelikler geri besleme sinir ağı ile sınıflandırıldığında %88, Radyal Temel fonksiyonu sinir ağı ile sınıflandırıldığında %89.33 ortalama başarıyı elde etmiştir.

[14] nolu çalışmada EMG sinyallerinden çıkarılan 16 adet zaman düzlemi (ortalama mutlak değer, kök kare ortalama, EMG'nin varyans, AR katsayısı vb.) özelliği YSA modeli ile eğitilerek sistemin doğruluğu hesaplanmıştır. Yapılan sınıflandırma sonucunda sistemin doğruluk oranı %96.7 olarak hesaplanmıştır.

[15] nolu çalışmada 4 sağlıklı bireyden fleksor digitorum kasından tek kanaldan alınan EMG sinyalleri yardımıyla 3 farklı el hareketini sınıflandırmak amaçlanmıştır. Bu amaçla alınan yüzey EMG sinyallerine dalgacık dönüşümü uygulanmıştır. Daha sonra çıkarılan öznitelikler YSA yardımıyla sınıflandırma yapılmıştır. Elde edilen sonuçlar Çizelge 1.3'te verilmiştir.

Çizelge 1.3. [15]'te elde edilen sonuçlar

Kişi No	Açma	Kapatma	Bilek Hareketi	Ortalama Sonuçlar
1.	100%	87.5%	88.9%	92%
2.	100%	95.7%	100%	98.6%
3.	100%	93.3%	78.9%	90.7%
4.	100%	83.3%	92.7%	91.7%
Ortalama	100%	89.95%	90.1%	93.25%

[16] nolu çalışmada altı sağlıklı kişinin küresel hareketleri gerçekleştirdikleri ve bu sinyallerin ön kolda bulunan beş kas üzerine elektrotlar yerleştirilerek EMG sinyalleri toplanmıştır. EMG sinyallerinden çıkarılan zaman düzlemi özellikleri istatistiksel model sınıflayıcı olan Lineer Diskriminant Analizi yöntemine girdi olarak verilmiştir. Yapılan çalışma sonucunda kas sinyalleri ile parmak pozisyonları arasında anlamlı bir ilişki olduğu gözlemlenmiştir. Bulunan sonuçların el hareketlerinin analizi ve protez kol çalışmaları için kullanışlı olacağı sonucuna varılmıştır.

[17] nolu çalışmada yüzey EMG sinyalleri alınıp 2 farklı sinir ağı modeli kullanılarak sınıflandırılması amaçlanmıştır. Flexion ve extension hareketlerinin gerçekleştirilmesiyle biceps kasından alınan EMG sinyallerinden açısal hız ve açısal yer değiştirmeye göre 2 zaman düzlemi parametresi(bütünleşmiş EMG, sıfır geçiş sayısı) çıkarılmıştır. Bu elde edilen parametreler 2 farklı yapay sinir ağı modeline giriş olarak verilmiştir. Çok katmanlı algılayıcı sinir ağı ve radyal tabanlı fonksiyon sinir ağı modelleri istatistiksel parametreler ve regresyon katsayı değeri kullanılarak kıyaslanmıştır. Yapılan sınıflandırma sonucunda ve radyal tabanlı fonksiyon sinir ağı modelinin daha iyi sonuç verdiği gözlemlenmiştir.

[18] nolu çalışmada farklı kas kasılmaları, dinamik kol hareketleri ve dış müdahale kuvvetleri tarafından uyarılan EMG sinyal çeşitleri incelenmiştir. Yapılan incelemeler sonucunda parmak hareketlerinin yanlış sınıflandırma oranı, kol pozisyonundan ziyade bilek pozisyonuna yüksek oranda bağlı olduğu görülmüştür.

## **1.2 Tezin Amacı**

Bu tez çalışmasının amacı; ön kol kaslarından sensörler yardımıyla alınan EMG sinyallerinden yapılan hareketin türünü doğru bir şekilde tespit etmektir. Bu amaçla EMG sinyalleri KZFD dönüşümü ile Z-F düzlemine alındıktan istatistiksel yöntemler, YİÖ ve GSEM teknikleri kullanılarak öznelik elde edilmiştir. Bu öznelikler YSA ile sınıflandırılmıştır.

## **1.3 Tezin Organizasyonu**

Tezin birinci bölümünde, teze genel bir bakış kazandırmak için EMG'nin tarihçesinden ve gelişiminden bahsedilmiştir. Sonraki kısımda literatürde yapılan çalışmalara değinilmiş ve çalışmalar hakkında bilgiler verilmiştir.

İkinci bölümde, ilk olarak Sinir Sistemi ve kas yapılarından bahsedilmiştir. Takip eden bölümde ise EMG sinyalinin tanımından ve özelliklerinden bahsedilmiştir. Üçüncü bölümde tezde kullanılan yöntemler anlatılmıştır. Dördüncü bölümde kullanılan sınıflandırma yönteminden bahsedilmiştir. Beşinci bölümde yapılan çalışma ve veri seti hakkında bilgi verilerek işlem adımları gösterilmiştir. Altıncı bölümde ise yapılan çalışmanın sonuçları verilmiştir.

## 2. EMG İŞARETLERİNİN ÖLÇÜLMESİ

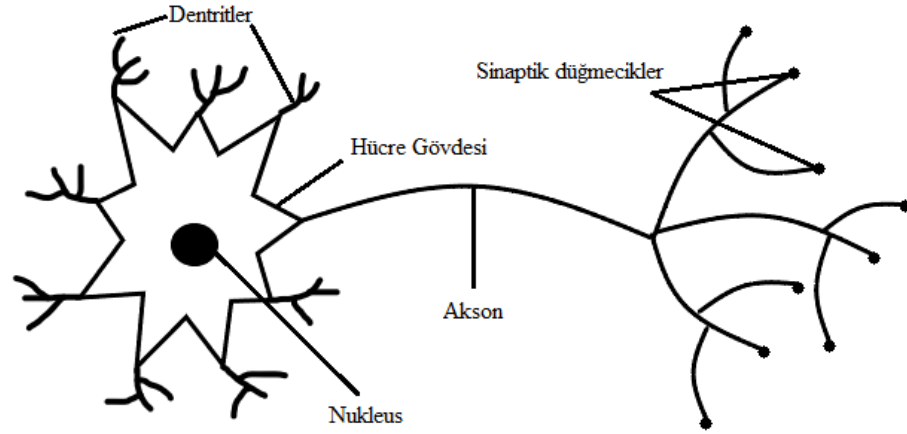
### 2.1 Sinir Sistemi

Sinir sistemi, vücudun iç ve dış ortamlardaki olayları algılama ve yanıtlama sistemidir. Dokunma hissi veren reseptörler çevremizde meydana gelen değişiklikler ile ilgili olarak Merkezi Sinir Sistemine (MSS) bilgi gönderir. MSS bu uyarılara hem hareket hem de endokrin sistemden bir miktar hormon değişikliği ile yanıt verir. Sinir sistemi anatomik olarak iki ana bölüme ayrılır. MSS ve Periferik Sinir Sistemi (PSS). MSS beyin ve omurilikte bulunan sinirlerdir. PSS ise MSS'nin dışında kalan sinir sistemini oluşturmaktadır.

#### 2.1.1 Nöronun Yapısı

Sinir sisteminin temel taşı nörondur. Şekil 2.1 gösterildiği gibi (1) hücre gövdesi, (2) dentrit, (3) akson olmak üzere nöron yapı olarak 3 parçaya ayrılabilir. Nöronun karar merkezi dentrit olarak adlandırılan hücre gövdesidir. Dentritler, hücre gövdesine doğru elektriksel impulsları iletebilen bir alıcı alan olarak çalışmaktadırlar. Akson (sinir lifleri) elektrik bilgisini hücre gövdesinden başka bir nöron veya efektör organına doğru taşır. Her nöronun sadece bir aksonu vardır fakat akson diğer nöronlarda, kas hücrelerinde veya salgı bezlerinde sonlanan birkaç parçaya ayrılabilir. Bir nöronun aksonu ile başka bir nöronun dentritleri arasındaki temas noktalarına sinaps denir.

Aksonlar, Schwann hücresi adı verilen bir hücre tabakası ile kaplıdır. Schwann hücrelerinin zarları, aksonun dışını örten miyelin adı verilen büyük miktarda bir lipit protein maddesi içerir. Akson boyunca miyelin segmentleri arasındaki boşluklara Ranvier düğümleri denir ve sinir iletiminde önemli rol oynarlar. Genel olarak, aksonun çapı ne kadar büyükse, sinir iletiminin hızı o kadar büyüktür. Bu neden, büyük miyelin kılıfına sahip olan aksonlar, küçük miyelinsiz liflerden daha hızlı impulsları iletmektedir [19].



Şekil 2.1. Nöron Yapısı

### 2.1.2 Hareketin Kas Kontrolü

Kas sistemi üç çeşit kasta oluşmaktadır. Bunlar kalbin yapısında bulunan kalp kası, istem dışı hareket eden ve iç organlarda bulunan düz kaslar ve tendonlar aracılığıyla iskelete bağlanan ve istemli olarak hareket edebilen çizgili kaslardır [20].

İnsan vücudu, toplam ağırlığının %40-%50'sini oluşturan 400'den fazla iskelet kasından meydana gelmektedir. İskelet kasları dışarıdan gelen şokları emerek iskelete güç ve koruma sağlar ve ayrıca kemiklerin hareket etmesini sağlar. Bir tek kasın değil kas gruplarının hareketi ile hareketler gerçekleşmektedir.

Vücut şeklini korumak, kuvvet için gerekli desteği sağlamak ve vücut ısısını dengelemek üzere iskelet kası vücutta üç temel işlevi yerine getirmektedir. Kaslar, bağlı olduğu ekleme göre farklı hareketlere imkân sağlamaktadırlar. Eklem açılarını azaltan kaslara fleksör ve eklem açılarını arttıran kaslara ise ekstansör kasları denmektedir [19,20].

İskelet kaslarının çizgilerini kalın ve ince filamentler oluşturur. Her kas lifinin hücre zarı, sarkomlemma olarak bilinir ve impulslar için iletken görevi görür. Kas hücreleri bir grup sarkomer olan miyofibrilleri oluşturur. Sarkomer, aktin, miyozin ve titinden oluşan üç çeşit miyofilament içeren multiprotein yapısıdır. İnce yapıları aktin oluştururken, kalın filamentler miyozin tarafından üretilmektedir.

Her kalın miyofilament altı ince miyofilament ile kaplıdır. Sarkomer iki Z çizgisi arasında yer alan ve miyofilamentler ile çatışarak ve elektron mikroskopisi

kullanılarak koyu ve farklı bantlar halinde ortaya çıkan kısımdır. Z-çizgisi etrafındaki yer izotropik grup (İ-Grubu) olarak tanımlanırken, Z-çizgisi arasındaki yer anizotropik gruptur (A-Grubu). A-grubunun içinde M-hatlarından oluşan bir palet H-grubu vardır. Ayrıca, A-grubunda miyozin filamanları bulunurken, İ-grubu aktin filamentlerinden oluşur. Kasın kasılması, kalsiyum iyonlarının aktin ve miyozin ile etleşimi ile sağlanır [21].

İnsanın iskelet kası, farklı yapıda kas liflerinin toplanmasıyla oluşmuştur. Kas liflerinin farklı olması farklı hareketleri yapmayı mümkün kılmaktadır. Kas liflerinin boyutu ve lif yapısı yapılmak istenen davranışa göre değişiklik gösterebilir. Bu esneklikten dolayı birçok fizik tedavi yöntemi geliştirilmiştir [22].

## 2.2 EMG

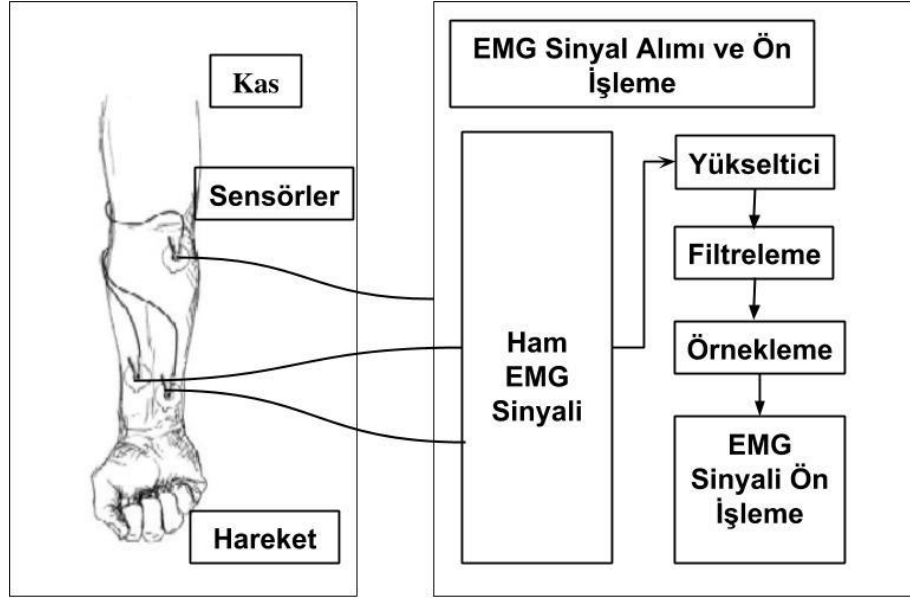
EMG, kas çalışması esnasında ortaya çıkan elektrik sinyalleridir. Kas dokusu sinirlerin yapısına benzer olarak elektriksel potansiyeller üretir. Bunlara kas aksiyon potansiyeli denir. Yüzey EMG, bu kas aksiyon potansiyellerinde bulunan mevcut bilgilerin kaydedilmesi için bir yöntemdir. EMG sinyalini kaydederken, sinyalin aslına uygunluğunu etkileyen iki ana konu vardır. Birincisi sinyal-gürültü oranıdır. Genel olarak gürültü, istenilen EMG sinyaline ait olmayan elektrik sinyali olarak tanımlanır. İkincisi ise EMG sinyaline ait herhangi bir frekans bileşeninin değiştirilmemesidir. EMG sinyalleri, doğrudan cilde monte edilen elektrotlardan elde edildiği için, cilt altında bulunan kasların aksiyon potansiyellerinin birleşimidir. Bu aksiyon potansiyelleri rastgele aralıklarla meydana geldikleri için herhangi bir anda EMG sinyali pozitif veya negatif voltaja sahip olabilir. Kas aksiyon potansiyelleri doğrudan kas içine yerleştirilmiş tel veya iğne elektrotlar kullanılarak elde edilebilir [2].

MÜAP, tek bir motor ünitesinin tüm kaslardan oluşan kas aksiyon potansiyellerinin toplamıdır. Denklem 2.1'de EMG sinyalinin basit matematiksel modeli gösterilmiştir:

$$x(n) = \sum_{k=0}^{N-1} h(k)e(n-k) + w(n) \quad (2.1)$$

Denklem 2.1'de  $x(n)$  EMG modelini,  $e(n)$  işlenen nokta,  $h(k)$  MÜAP,  $w(n)$  sıfır ortalama yapan Gauss gürültüsünü ve  $N$  motor ünite atışlarını göstermektedir.

Sinyaller elektrot yardımıyla toplanır ve yükseltilir. Birinci amplifikatör olarak bir diferansiyel amplifikatör kullanılır. Sinyal kaydedilmeden önce alçak, yüksek frekanslı gürültüler ve sistemden kaynaklanabilecek artefaktları ortadan kaldırmak için ön işlemden geçebilir [2]. EMG sinyalinin ölçülme şeması Şekil 2.2’de gösterilmiştir.



Şekil 2.2. EMG Sinyalinin Ölçülmesi

### 2.2.1. Gürültü Çeşitleri

Yükseltilmeden önce EMG sinyalinin genliği 0-10 mV aralığındadır. EMG sinyalleri farklı dokularda hareket ederken gürültü eklenerek ilerler. Bu yüzden elektriksel gürültünün özelliklerini bilmek önemlidir. EMG sinyalini etkileyecek olan elektriksel gürültü aşağıda belirtilen çeşitlere ayrılabilir:

- *Elektronik cihazlardan kaynaklı gürültü:* Tüm elektronik cihazlar gürültü üretir. Bu gürültü ortadan kaldırılamaz fakat yüksek kaliteli bileşenler kullanılarak azaltılabilir.
- *Ortam gürültüsü:* Vücudumuz sürekli elektromanyetik radyasyon altında olduğu için bu radyasyon vücutta bir gürültü kaynağını meydana getirir. Ortam gürültüsü EMG sinyalinden 1-3 kat büyüklüğü olan bir genliğe sahip olabilir.
- *Hareket kaynaklı artefakt:* Hareket sonucu oluşan artefaktlar verilerde düzensizliğe neden olur. Hareket artefaktı sebebi elektrot yüzeyi ve elektrot

kablosundan dolayı oluşmaktadır. Bu artefakt sistemin düzgün tasarımı ile azaltılabilir.

- *Sinyalin yapısal kararsızlığı*: EMG'nin genliği rastgele oluşmaktadır. EMG sinyali, 0-20 Hz frekans aralığında çalışan motor ünitelerinden etkilenir. Bu tip gürültünün sinyalden çıkarılması önemlidir [2].



### 3. ÖZNETELİK ÇIKARIMI

Bu bölümde sinyallerden öznitelik çıkarmak amacıyla sinyallere uygulanan yöntemlerden bahsedilecektir. Öncelikle KZFD'nün temeli olduğu için Fourier Dönüşü anlatılacak ve akabinde KZFD anlatılacaktır. Devam eden başlıklarda ise sırasıyla İstatistiksel Yöntemlerden, YİÖ ve GSEM anlatılacaktır.

#### 3.1 Fourier Dönüşümü

Fourier dönüşümü, bilim ve mühendislikte ortaya çıkan farklı tipte diferansiyel denklemlerin çözümü için en güçlü tekniktir. Hem analitik hem de sayısal yaklaşımların çeşitliliği bu dönüşümlere dayanmaktadır. Bu dönüşümler, sinyal bilgilerinin elde edilmesi ve bu sinyallerin işlenmesi için kullanılan çok önemli bir yöntemdir. Bu sinyallerin temsili için, trigonometrik taban fonksiyonları kullanılmaktadır ve bu fonksiyonların trigonometrik bir seri olarak açılımı, sinyaller hakkında bilgi edinilmesini sağlamaktadır. Fourier dönüşümleri ile bir sinyal, farklı frekans, faz ve genlikte kosinüs ve sinüs fonksiyonlarının toplamı olarak ifade edilmektedir.

$T$  periyodu ile periyodik olan  $f(\tau)$  fonksiyonunu ele alalım.

$$f(\tau + T) = f(\tau) \quad (3.1)$$

Denklem 3.1'de periyodu  $2\pi$  yapmak için  $\tau$  değerini daima yeniden ölçekleyebiliriz. Bunu yapmak için, yeni bir bağımsız değişken  $t = \frac{2\pi}{T}\tau$  tanımlanmakta ve böylece yeni fonksiyon Denklem 3.2'deki gibi olmaktadır.

$$f\left(\frac{t}{2\pi}\right) = f\left(\frac{t}{2\pi} + 1\right) \quad (3.2)$$

$2\pi$  periyodu ile periyodik olan gerçek bir  $t$  değişkeninin Denklem 3.2'deki gibi  $f\left(\frac{t}{2\pi}\right)$  fonksiyonuna eşit olmasına izin verilip, bu fonksiyonun davranışı  $2\pi$  uzunluğunda (örneğin:  $(-\pi, \pi)$  aralığında) düşünülmelidir. Bu düşünce,  $f\left(\frac{t}{2\pi}\right)$  fonksiyonu gibi basit fonksiyonların trigonometrik serisine ayırmaktır. Joseph Fourier (1768-1830) bu trigonometrik seriyi sinüs ve kosinüs fonksiyonlarının toplamı olarak Denklem 3.3'teki gibi ifade etmektedir.

$$f\left(\frac{t}{2\pi}\right) = \frac{a_0}{2} + \sum_{n=1}^{\infty} [a_n \cos(nt) + b_n \sin(nt)] \quad (3.3)$$

Denklem 3.3'te gösterilen trigonometrik seri fourier serisi açılımı olarak adlandırılmaktadır.  $a_n$  ve  $b_n$  sabit katsayılarıdır ve  $f$  fonksiyonunun fourier katsayıları

olarak adlandırılmaktadırlar. Fourier dönüşümü ise, Denklem 3.3'te verilen fourier katsayılarını bulma problemidir. Bu katsayıları bulmak için, Denklem 3.4'te gösterildiği gibi sinüs ve kosinüs fonksiyonlarının ortogonalitesi kullanılmaktadır.

$$\begin{aligned} \int_{-\pi}^{\pi} \cos(nt) \cos(mt) \partial t &= \int_{-\pi}^{\pi} \frac{1}{2} [\cos((m-n)t) + \cos((m+n)t)] \partial t \\ &= \begin{cases} 2\pi, & m = n = 0 \\ \pi, & m = n \neq 0 \\ 0, & m \neq n \end{cases} \\ &= \begin{cases} 2\pi & m = n = 0 \\ \pi \delta_{mn} & m \neq 0 \end{cases} \end{aligned} \quad (3.4)$$

Benzer şekilde,

$$\begin{aligned} \int_{-\pi}^{\pi} \sin(nt) \sin(mt) \partial t &= \int_{-\pi}^{\pi} \frac{1}{2} [\cos((m-n)t) - \cos((m+n)t)] \partial t \\ &= \begin{cases} 0 & m = 0 \\ \pi \delta_{mn} & m \neq 0 \end{cases} \end{aligned} \quad (3.5)$$

ve

$$\begin{aligned} \int_{-\pi}^{\pi} \sin(nt) \cos(mt) \partial t &= \int_{-\pi}^{\pi} \frac{1}{2} [\sin((m-n)t) + \sin((m+n)t)] \partial t \\ &= 0 \end{aligned} \quad (3.6)$$

Denklem 3.3'te verilen seri için ortogonalite kullanılarak fourier katsayıları Denklem 3.7 ve Denklem 3.8'deki gibi olmaktadır.

$$a_n = \frac{1}{\pi} \int_{-\pi}^{\pi} f(t) \cos(nt) \partial t \quad (3.7)$$

$$b_n = \frac{1}{\pi} \int_{-\pi}^{\pi} f(t) \sin(nt) \partial t \quad (3.8)$$

Fourier açılımında kolaylık sağlayan bir başka önemli özellik, fourier katsayılarının fonksiyonun tek veya çift olma durumuna göre tek bir harmonik cinsinden hesaplanabilmesidir. Eğer bir fonksiyon  $f(t) = f(-t)$  ise, çift fonksiyondur ve tüm  $n$  değerleri için  $b_n = 0$  olur. Bu fonksiyon sadece kosinüslü terim içerir. Aynı şekilde  $f(t) = -f(-t)$  ise, tek fonksiyondur ve tüm  $n$  değerleri için  $a_n = 0$  olur. Bu fonksiyon da, sadece sinüslü terim içerir.

Taylor seri açılımı kullanılarak kompleks fourier serisinin kompleks hali bulunabilir.

$$e^{it} = 1 + it + \frac{(it)^2}{2!} + \frac{(it)^3}{3!} + \dots, i = \sqrt{-1} \quad (3.9a)$$

$$e^{it} = \left(1 - \frac{t^2}{2!} + \frac{t^4}{4!} + \dots\right) + i\left(t - \frac{t^3}{3!} + \frac{t^5}{5!} + \dots\right) \quad (3.9b)$$

$$e^{it} = \cos(t) + i \sin(t) \quad (3.9c)$$

$$\cos(t) = \frac{1}{2}(e^{it} + e^{-it}) \text{ ve } \sin(t) = \frac{1}{2i}(e^{it} - e^{-it}) \quad (3.9d)$$

Denklem 3.9'da gösterilen ifadeler Fourier seri ifadesi olan Denklem 3.3'te yerine yazılırsa, kompleks fourier seri açılımını elde edilir.

$$\begin{aligned} f(t) &= \frac{a_0}{2} + \sum_{n=1}^{\infty} \left[ a_n \frac{e^{int} + e^{-int}}{2} + b_n \frac{e^{int} - e^{-int}}{2i} \right] \\ &= \frac{a_0}{2} + \sum_{n=1}^{\infty} \frac{a_n - ib_n}{2} e^{int} + \sum_{m=-1}^{-\infty} \frac{a_{-m} + ib_{-m}}{2} e^{imt} \end{aligned} \quad (3.10)$$

Denklem 3.10'da  $m = -n$  olarak değiştirildiğinde, fourier serisinin kompleks basit formu Denklem 3.12'de verilen katsayı değeri ile Denklem 3.11'deki gibi olmaktadır.

$$x(t) = \sum_{n=-\infty}^{\infty} X_n e^{in(2\pi f_0)t} \quad (3.11)$$

$$X_n = \frac{1}{T} \int_{-T/2}^{T/2} x(t) e^{-in(2\pi f_0)t} dt \quad (3.12)$$

Denklem 3.11 ve Denklem 3.12'de fourier serisi,  $T = 1/f_0$  periyodu ile  $x(t)$  kompleks bir periyodik fonksiyon için yazılmıştır. Fourier katsayısı olan  $X_n$  karmaşık bir değerdir.

Fourier dönüşümü, periyodik olmayan fonksiyonların çözümüne izin vermektedir. Periyod  $T \rightarrow \infty$  ile bir fonksiyon gibi periyodik olmayan fonksiyonların yaklaşımı takip edilecektir. Karmaşık fourier serisinden başlayarak, Denklem 3.12'de bulunan  $X_n$  karmaşık değeri Denklem 3.11'de yerine yazılırsa Denklem 3.13 elde edilir.

$$x(t) = \sum_{n=-\infty}^{\infty} \frac{1}{T} \int_{-T/2}^{T/2} x(\varepsilon) e^{in2\pi f_0(t-\varepsilon)} d\varepsilon \quad (3.13)$$

Bir Fourier serisinde Fourier amplitüdüleri, ayrı frekanslarda sinüzoidal salınımlarla ilişkilidir. Bu frekanslar  $f_0 = 1/T$  temel frekanslar ve yüksek harmonikler için  $f = \frac{2}{T}, \frac{3}{T} \dots$  sıfırdır.  $T \rightarrow \infty$  limiti alınırken, komşu frekansların arasındaki mesafe Denklem 3.14'teki gibi olacaktır ve  $f = (0, \infty)$  sürekli frekanslarda fourier amplitüdüleri ile sonuçlanmaktadır.

$$(n+1)f_0 - nf_0 = f_0 = \frac{1}{T} \rightarrow \partial f \quad (3.14)$$

Belirli küçük frekans aralığı için, bu aralıkta yer alan ayrı frekans harmoniğinin  $n$  sayısı, komşu frekanslar arasındaki mesafenin  $T^{-1}$  sifıra düştüğü sınırdaki bir artışa neden olur ve  $f = n/T$  yeni sürekli değişken olarak hizmet edecektir. Bu işlemler sonucunda limit alındıktan sonra  $x(t)$  ifadesi Denklem 3.15'teki gibi olur. Denklem 3.15 fourier integrali olarak adlandırılmaktadır.

$$x(t) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x(\tau) e^{i2\pi f(t-\tau)} d\tau df$$

$$x(t) = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{\infty} x(\tau) e^{-i2\pi f\tau} \partial\tau \right] e^{i2\pi ft} \partial f \quad (3.15)$$

Denklem 3.15'te gösterilen ifadelerden yola çıkarak fourier dönüşüm ve forier dönüşümün tersi ifadeleri Denklem 3.16 ve Denklem 3.17'deki gibi olmaktadır.

$$\text{Fourier Dönüşüm: } \hat{x}(f) = F(x(t)) = \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} \partial t \quad (3.16)$$

$$\text{Fourier Dönüşümün Tersisi: } x(t) = F^{-1}(\hat{x}(f)) = \int_{-\infty}^{\infty} \hat{x}(f) e^{i2\pi ft} \partial f \quad (3.17)$$

$\hat{x}(f)$  fonksiyonu, fourier serisindeki fourier katsayılarının eşdeğeridir. Sürekli frekans alanında  $f \in (-\infty, \infty)$  aralığındadır. Bir anlamda  $x(t)$  bir sinüs dalgasından oluştuğu düşünülebilir.  $x(t)$  ve  $\hat{x}(f)$  ilgili fonksiyonun iki eşdeğer temsilidir ve bu temsiller fourier dönüşümü ile bağlanır. Genel olarak,  $\hat{x}(f)$  hem büyüklük hem de faz bilgisini içeren karmaşık değerli bir fonksiyondur. Fourier dönüşümü ile ilgili aşağıdaki özellikler tanımlanabilir.

- Gerçek değerli  $x(t)$  fonksiyonu için;

$$\hat{x}(f) = \hat{x}(-f)^* \quad (3.18)$$

‘\*’ kompleks fourier serinin eşleniğini belirtir.

- $x(t)$  fonksiyonu gerçek ise,  $x(-t)$  nin fourier dönüşümü Denklem 3.19'daki gibi olur.

$$F|x(-t)| = \hat{x}(-f) = \hat{x}(f)^* \quad (3.19)$$

- Fourier dönüşümün tanımı ve parçaların birleştirilmesi kullanılarak Denklem 3.20'deki ifade gösterilebilir. Bu ifade  $x(t)$  fonksiyonunun n. dereceden türevidir.

$$F \left[ \frac{\partial^n x(t)}{\partial t^n} \right] = (-i2\pi f)^n \hat{x}(f) \quad (3.20)$$

- Parseval ilişkisi, bir fonksiyonun toplam gücünün, zaman ve frekans alanında aynı olduğunu garanti eder, çünkü zaman ve frekans alanlarındaki fourier dönüşümleri çiftinin normları eşittir. Yani;

$$\|x\|^2 = \|\hat{x}\|^2 \quad (3.21)$$

$$\|x\|^2 = \int_{-\infty}^{\infty} |x(t)|^2 \partial t \quad \|\hat{x}\|^2 = \int_{-\infty}^{\infty} |\hat{x}(f)|^2 \partial f \quad (3.22)$$

- Fourier dönüşümleri ve fourier dönüşümünün tersi lineerdir.  $c_1$  ve  $c_2$  sabit katsayılar olmak üzere;

$$F(c_1 x(t) + c_2 y(t)) = c_1 \hat{x}(f) + c_2 \hat{y}(f) \quad (3.23)$$

$$\begin{aligned}
F(c_1x(t) + c_2y(t)) &= \int_{-\infty}^{\infty} c_1x(t) e^{-i2\pi ft} \partial t + \int_{-\infty}^{\infty} c_2y(t) e^{-i2\pi ft} \partial t \\
&= c_1 \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} \partial t + c_2 \int_{-\infty}^{\infty} y(t) e^{-i2\pi ft} \partial t = c_1\hat{x}(f) + c_2\hat{y}(f)
\end{aligned}$$

- İki fonksiyonun çarpımının fourier dönüşümü:

$$F(x(t)y(t)) = \hat{x}(f) * \hat{y}(f) \quad (3.24)$$

- $x(t)$  fonksiyonunun  $y(t)$  fonksiyonu ile konvolüsyonunun fourier dönüşümü:

$$F[x(t).y(t)] = F[x(t)] * F[y(t)] = \int_{-\infty}^{\infty} \hat{x}(\tau) \hat{y}(f - \tau) \partial \tau \quad (3.25)$$

- $x(t)$  fonksiyonu bir  $c_1$  reel sayısı ile ölçeklendirildiğinde fourier dönüşümü:

$$F(x(c_1t)) = \frac{\hat{x}\left(\frac{f}{c_1}\right)}{|c_1|} \quad (3.26)$$

### 3.1.1 Kısa Zamanlı Fourier Dönüşümü

Fourier dönüşümü, sinyalin tüm zaman zarfında analiz edildiğini varsayar ki bu da frekans alanında zaman kavramının olmamasını ve aynı zamanda zaman içinde frekans değişimi kavramının olmadığını gösterir. Ancak, frekans içeriği zamanla değişebilen sinyaller vardır, tipik bir örnek, zamanla yükselen ve düşen konuşma sinyalidir. Fourier dönüşümü bize zaman içinde bu frekans değişimlerini gösteremez. Bu durum KZFD ile çözülür. KZFD zaman frekansı gösterimlerini hesaplamak için basit ve etkili bir araçtır. KZFD, bir sinyalin zaman ve frekansa dayalı görünüşleri arasında bir çeşit uzlaşmayı temsil eder. Bir sinyal olayının ne zaman ve ne sıklıkta gerçekleştiği hakkında bazı bilgiler sağlar. Bununla birlikte, performansı büyük ölçüde kullanılan pencerenin şekline ve boyutuna bağlıdır. Daha uzun pencereler iyi frekans çözünürlüğü verirken, daha kısa pencereler iyi zaman çözünürlüğü sağlar.

KZFD, bir sinyalin zaman içindeki frekans değişimini değerlendirir. Bunu başarmak için, sinyal belirli uzunluktaki bloklara kesilir ve daha sonra her bir bloğun Fourier dönüşümü hesaplanır. Her bloktaki frekans değerleri yan yana bırakılarak, sinyalin zamana bağlı gösterdiği frekans değeri değişimleri görülebilir. KZFD, zamanı belirli uzunluktaki bloklara ayırma işlemini pencere fonksiyonları (dikdörtgen, Hann ve Hamming) ile yapmaktadır. Şekil 3.2’de bazı pencere fonksiyonları gösterilmiştir. Tüm sinyal boyunca bloklara ayırma işlemi ise, kayan pencereler aracılığıyla gerçekleştirilir. Yani KZFD, pencere fonksiyonlarından herhangi birini kullanarak, bu fonksiyonları sinyalin ölçüm periyodu süresince öteleyerek ve her öteleme adımında pencere fonksiyonu içinde kalan sinyale fourier dönüşümü uygulanır. Belirli

aralıklarla yapılan bu işlemler, sinyalin zamana bağlı olarak frekans değişimini ortaya koyar. KZFD işleyiş adımları şu şekildedir.

**Adım 1:** Belirli uzunluğa sahip bir pencere fonksiyonu seçin.


**Adım 2:**  $t = 0$ 'da sinyalin üzerine pencereyi yerleştirin.

**Adım 3:** Bu pencereyi kullanarak sinyali kesin.


**Adım 4:** Kesilmiş sinyalin fourier dönüşümünü hesaplayın, sonuçları kaydedin.

**Adım 5:** Pencereyi adım adım sağa kaydırın.

**Adım 6:** Pencere sinyalin sonuna ulaşana kadar 3. adıma geçin.



Şekil 3.1. KZFD Görünümü [32]



Şekil 3.2. Pencere fonksiyonları örnekleri ve frekans cevapları [33]

Kısa zamanlı fourier dönüşümünün matematiksel gösterimi Denklem 3.27'deki gibidir [34].

$$KSFD \{x(t)\}(\tau, \omega) = \int_{-\infty}^{\infty} x(t)\omega(t - \tau)e^{-j2\pi ft} \quad (3.27)$$

- $x(t)$ , t anında giriş sinyali
- $\tau$ , öteleme miktarı
- $\omega$  ise pencere fonksiyonudur.

Kısa zamanlı fourier dönüşümünün ayrık formu ise Denklem 3.28'deki gibidir.

$$x(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]\omega[n - m]e^{-j2\pi fn} \quad (3.28)$$

Denklem 3.28'de  $n$  zamanında  $x[m]$  sinyalinin kısa zaman bölümü  $f_n[m] = x[m]\omega[n - m]$  şeklinde gösterilir.

KZFD'nin büyüklüğünün grafiksel gösterimine spektrogram denilmektedir. Spektrogram ise Denklem 3.29'teki gibi ifade edilmektedir [34].

$$\text{spektrogram } \{x(t)\}(\tau, \omega) = |KSFD\{x[n]\}(m, \omega)|^2 \quad (3.29)$$

### 3.2 İstatistiksel Öznitelik

Ortalama, standart sapma ve entropi özellikleri genellikle görüntünün karakteristiğini elde etmek amacıyla kullanılmıştır [23].

*Ortalama*, görüntü yoğunluğunun ortalama değeridir. Ortalama formülü Denklem 3.30'da verilmiştir. Burada N eleman sayısını  $A_i$  ise i. elemanı göstermektedir.

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \quad (3.30)$$

*Standart Sapma*, verilerin yayılımının matematiksel olarak ifade etmek için kullanılan bir ölçüdür. Standart sapma formülü Denklem 3.31'de verilmiştir. Denklemde  $\mu$ , ortalama, N eleman sayısını  $A_i$  ise i. elemanı göstermektedir.

$$STD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2} \quad (3.31)$$

*Entropi*, verilerin düzensizlik ölçümünde kullanılır. Entropi Denklem 3.32'de verilen formül ile hesaplanmaktadır. Denklemde p normalleştirilmiş histogram sayılarını içermektedir.


$$\text{ENTROPİ} = -\sum(p \cdot \log_2(p)) \quad (3.32)$$

### 3.3 Yerel İkili Örüntüler (YİÖ)

Son birkaç yılda, yerel ikili örüntüler, görüntü işleme ve bilgisayarlı görme alanlarına olan ilgiyi arttırmıştır. Parametrik olmayan bir yöntem olan, YİÖ, her bir pikseli komşu piksellerle karşılaştırarak görüntülerin yerel yapılarını verimli bir şekilde özetlemektedir. YİÖ'nin en önemli özellikleri, monotonik parlaklık değişikliklerine ve hesaplama sadeliğine olan toleransıdır. YİÖ, aslında doku analizi için önerilmiştir, fakat yerel yapıları tanımlamak için basit ama güçlü bir yaklaşım olduğu yapılan çalışmalarla kanıtlanmıştır. Örneğin, yüz görüntü analizi, görüntü ve video alma, çevre modelleme, görsel inceleme, hareket analizi, biyomedikal ve hava görüntü analizi, uzaktan algılama gibi pek çok uygulamada yaygın olarak kullanılmaktadır.




Orijinal YİÖ operatörü, bir görüntünün piksellerini, her pikselin çevresindeki yerel yapıyı kodlayan yerel ikili örüntülerle veya YİÖ kodları olarak adlandırılan ondalık sayılarla etiketler. Yani, görüntünün her bir pikseli için bir etiket oluşturmaktadır ve bu etiketler sıfır ve bir değerlerinden oluşmaktadır. Oluşturulan bu etiketler, merkez piksel değerinin  $N \times N$  komşuluğunda bulunan piksel değerlerinin karşılaştırılması ile elde edilir. YİÖ operatörü, Şekil 3.3'te gösterildiği gibi ilerler ve her piksel, merkez piksel değerinin çıkarılmasıyla,  $3 \times 3$  komşuluğunda, sekiz komşu ile karşılaştırılır. Elde edilen negatif değerler 0 ile ve diğerleri ise 1 ile kodlanır. Tüm bu ikili kodların, sol üstten başlayarak saat yönünde bir araya getirilmesiyle ikili bir sayı elde edilir ve etiketleme için karşılık gelen ondalık değer kullanılır. Türetilmiş ikili sayılar yerel ikili örüntüler veya YİÖ kodları olarak adlandırılır.



Şekil 3.3. Temel YİÖ operatörü örneği [30]

Şekil 3.3'deki örnekte gösterildiği gibi temel YİÖ operatörünün bir kısıtlaması, küçük  $3 \times 3$  komşuluğunda büyük ölçekli yapılarla baskın özellikleri yakalayamamasıdır. Bu nedenle, dokuyu farklı ölçeklerde ele almak için bu operatör, daha sonra farklı boyutların komşuluğunda kullanılmak için genelleştirilebilir. Yerel bir komşu, etiketlenecek pikselde merkezlenmiş bir daire üzerinde eşit aralıklarla yerleştirilmiş örnekleme noktaları kümesi olarak tanımlanır ve piksellerin içine girmeyen örnekleme noktaları, doğrusal enterpolasyon kullanılarak enterpolasyona tabi tutulur, böylece komşuda herhangi bir yarıçap ve herhangi bir sayıda örnekleme noktasına izin verilir. Şekil 3.4'de genişletilmiş YİÖ operatörünün bazı örnekleri gösterilmektedir, burada dairesel komşulukların temsili için (P, R) notasyonları kullanılmaktadır. Bu notasyonlarla YİÖ operatörü,  $LBP_{(P,R)}$  şeklinde gösterilmektedir. P notasyonu, komşu sayısını, R notasyonu ise, örnekleme yarıçapını ifade etmektedir.



Şekil 3.4. Genişletilmiş YİÖ operatörünün örnekleri [30]

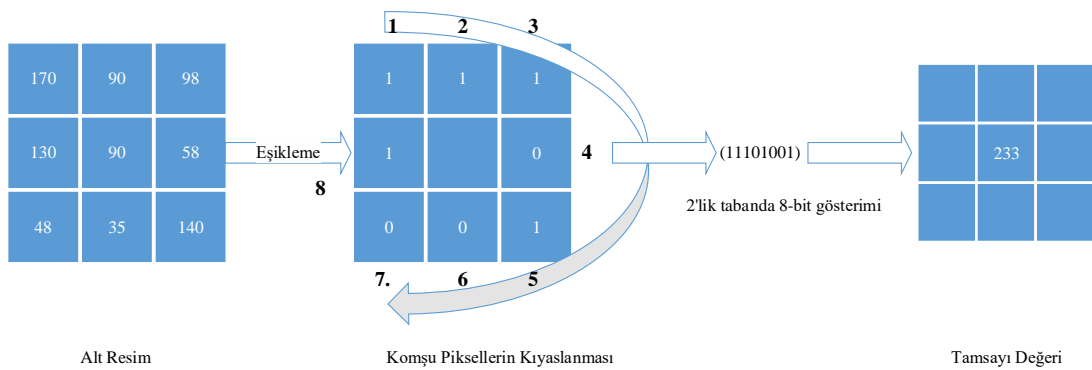
Şekil 3.4'deki örneklerde dairesel (8,1), (16,2) ve (24,3) komşuluklar gösterilmiştir. YİÖ operatörleri,  $YİÖ_{(8,1)}$ ,  $YİÖ_{(16,2)}$  ve  $YİÖ_{(24,3)}$  şeklinde ifade edilmektedirler. Biçimsel olarak,  $(x_c, y_c)$ 'de bir piksel verildiğinde, elde edilen YİÖ Denklem 3.33'deki gibi ondalık biçimde ifade edilebilir:

$$YİÖ_{(p,R)}(x_c, y_c) = \sum_{p=0}^{p-1} s(i_p - i_c) 2^p \quad (3.33)$$

Denklem 3.33'te  $i_c$  ve  $i_p$  sırasıyla, merkez pikselin gri seviye değerlerini ve merkez pikselin komşularını temsil etmektedirler.  $s(x)$  fonksiyonu ise Denklem 3.34'deki gibi tanımlanmaktadır.

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (3.34)$$

Denklem 3.34'te  $x$ , merkez pikselle komşu piksel arasındaki farkı belirten değerdir.  $s(x)$  ise, YİÖ operatörü sonucunda elde edilen bitleri göstermektedir.  $YİÖ_{(p,R)}$  operatörü, komşuda P piksellerinin oluşturduğu  $2^p$  farklı ikili örüntüye karşılık,  $2^p$  farklı çıkış değeri üretir. Denklem (3.33) ve (3.34) kullanılarak  $YİÖ_{(8,1)}$  operatörünün uygulaması Şekil 3.5'teki gibidir [30].



Şekil 3.5.  $YİÖ_{(8,1)}$  operatörünün uygulaması

### 3.4 Gri Seviye Eş-Oluşum Matrisi (GSEM)

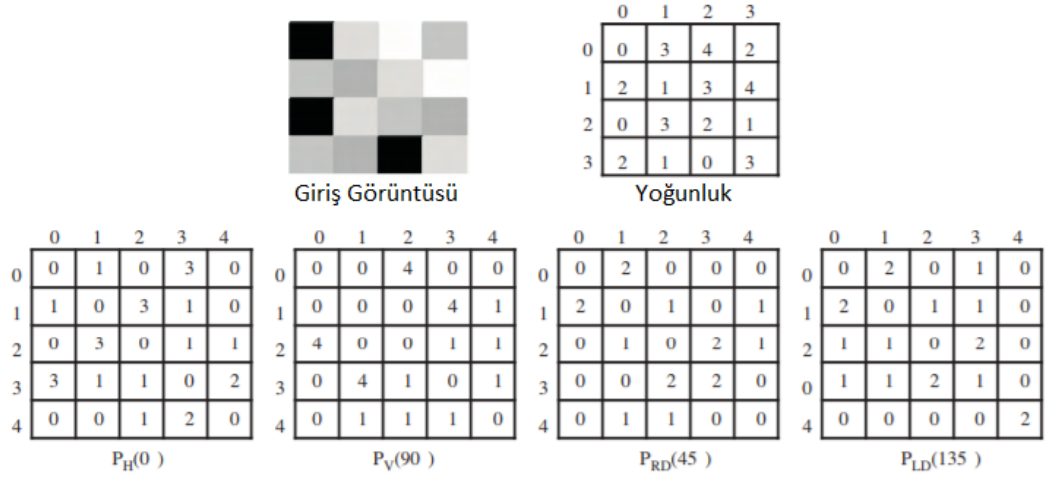
Doku, bir görüntüdeki ilgili bölgelerin tanımlanmasında kullanılan önemli bir özelliktir. Doku tanımlamak için en basit yaklaşımlardan biri, bir görüntü veya bölgenin yoğunluk histogramının istatistiksel momentlerini kullanmaktır. Hesaplama sadece histogramların kullanılması, yalnızca yoğunlukların dağılımı hakkında bilgi taşıyan, ancak bu dokudaki birbirine göre piksellerin göreceli konumuyla ilgili olmayan doku ölçümleriyle sonuçlanacaktır. Eş-oluşum matrisi gibi istatistiksel bir yaklaşım kullanmak, bir görüntüdeki komşu piksellerin göreceli konumu hakkında faydalı bilgiler sağlamaya yardımcı olacaktır. GSEM 1973'te Haralick tarafından doku özellik çıkarımı için önerilen ilk yöntemlerden biridir. O zamandan beri birçok doku analiz uygulamasında yaygın olarak kullanılmaktadır ve doku analizi alanında önemli bir özellik çıkarma yöntemi olarak kalmıştır. En çok bilinen ve kullanılan doku analiz yöntemlerinden biri olan gri seviye eş-oluşum matrisi, ikinci dereceden istatistiklerle ilgili görüntü özelliklerini tahmin eder. GSEM deki her bir giriş  $(i, j)$ , orijinal görüntüde ayrı bir  $d$  mesafesi olan  $i$  ve  $j$  gri seviyeleri çiftinin oluşum sayısına karşılık gelir.

Bir görüntü  $I$  verildiğinde,  $N \times N$  büyüklüğünde, eş-oluşum  $P$  matrisi Denklem 3.35'deki gibi tanımlanabilir.

$$P(i, j) = \sum_{x=1}^N \sum_{y=1}^N \begin{cases} 1, & I(x, y) = i \text{ ve } I(x + \Delta_x, y + \Delta_y) = j \\ 0, & \text{diğer durumlar için} \end{cases} \quad (3.35)$$


Denklem 3.35'de,  $(\Delta_x, \Delta_y)$  parametreleri ilgili piksel ve onun komşuluğu arasındaki mesafeyi belirtmektedir. Bu parametreler aynı zamanda eş-oluşum matrisini dönmeye duyarlı hale getirmektedir. Görüntünün dönüşü 180 dereceye eşit olmayacak şekilde bir ofset vektörünün seçilmesi, aynı (döndürülmüş) görüntü için farklı bir eş-oluşum matrisiyle sonuçlanacaktır. Bu durumda matris farklı açılar ile elde edilecek ve özniteliğe dönülmeden matrise bağımsızlık kazandırılacaktır. Eş-oluşum matrisi genellikle 4 yönde elde edilir.  $0^\circ$  için  $[0, \Delta]$ : P yatay,  $45^\circ$  için  $[-\Delta, \Delta]$ : P sağ köşegen,  $90^\circ$  için  $[-\Delta, 0]$ : P dikey ve  $135^\circ$  için  $[-\Delta, -\Delta]$ : P sol köşegen.  $\Delta$  mesafe parametresidir.

Şekil 3.6'da olası dört yönde bir komşu piksel olarak tanımlanan  $\{[0,1], [-1,1], [-1,0], [-1,-1]\}$  ofset değerleri için  $N=5$  seviyelerini kullanarak bir pikselin dört eş-oluşum matrisini oluşturmak için işlemin ayrıntıları gösterilmiştir [31].



Şekil 3.6. N = 5 seviyeleri ve dört farklı ofset için birlikte-oluşum matrisi üretimi

Giriş görüntüsünün iki komşu pikseli (2,1)  $P_H$  eş-oluşum matrisinde 3 olarak yansıtılmıştır. Çünkü giriş görüntüsünde birbirine komşu piksel yoğunluğu 2 ve piksel yoğunluğu 1'in 3 oluşumu vardır. Komşu pikseller (1,2)  $P_H$  eş-oluşum matrisinde 3 defa tekrar meydana geleceği için (2,1) ve (1,2) piksellerinin  $P_H$  matrisleri simetrik olacaktır. Aynı şekilde  $P_V$ ,  $P_{RD}$  ve  $P_{LD}$  eş-oluşum matrisleri hesaplanmıştır. Oluşturulan bu dört matris sınıflandırma için ayrı ayrı kullanılır, ardından nihai sonuç bu dört sonucun birleştirilmesiyle oluşturulmaktadır. Bu matrisler simetrik olduğundan, vektörlerin oluşturulmasında üst veya alt diyagonal matris katsayılarının kullanılması daha uygundur.



Şekil 3.7. Dört GSEM matrisleri için karar füzyonu [31]

Farklı gri seviye eş-oluşum matrisleri arasındaki benzerliği tahmin etmek için Haralick, bu matrislerden çıkarılmış 14 istatistiksel özellik önermiştir. Bu özellikler,  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$  yönleri kullanılarak elde edilen eş-oluşum matrislerinin her birinin özelliklerinin hesaplanmasıyla üretilir ve sonra bu dört değerlerin ortalaması alınır.

Mesafe parametresini temsil eden  $\Delta$  sembolü, bir veya daha fazla seçilebilir. Genel olarak, mesafe parametresi değeri 1 olarak ayarlanır. Bu 14 istatistiksel özellikten bir vektör, eş-oluşum matris içeriklerinin karakterizasyonu için kullanılır. Hesaplama karmaşıklığını azaltmak için, bu özelliklerden sadece bazıları seçilmiştir.

Bu çalışmada kullanılan GSEM bilgileri aşağıda verilen formüllerden elde edilmiştir. Kontrast, entropi, toplam ortalama, toplam varyans, toplam entropi, fark varyansı, fark entropisi ve korelasyon bilgi ölçüsü aşağıdaki biçimde formülize edilebilir [24]:

$Ng$ , kullanılan gri seviyelerinin sayısıdır.  $P_x(i)$ ,  $P(i,j)$ 'nin satırlarının toplanmasıyla elde edilen marjinal olasılık matrisindeki  $i$ 'ninci girdidir.

$$P_x(i) = \sum_{j=1}^{Ng} P(i, j) \quad (3.36)$$

$$P_y(i) = \sum_{i=1}^{Ng} P(i, j) \quad (3.37)$$

$$P_{x+y}(k) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} P(i, j), \quad i + j = k, \quad k = 2, 3, \dots, 2Ng \quad (3.38)$$

$$P_{x-y}(k) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} P(i, j), \quad |i - j| = k, \quad k = 0, 1, \dots, Ng - 1 \quad (3.39)$$

$$Kontrast = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} P(i, j) \right\}, \quad |i - j| = n \quad (3.40)$$

$$Entropi = - \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} P(i, j) \log[P(i, j)] \quad (3.41)$$

$$Toplam\_Ortalama = \sum_{i=2}^{2Ng} iP_{x+y}(i) \quad (3.42)$$

$$Toplam\_Varyans = \sum_{i=2}^{2Ng} \left( i - \left[ \sum_{i=2}^{2Ng} iP_{x+y}(i) \right] \right)^2 \quad (3.43)$$

$$Toplam\_Entropi = - \sum_{i=2}^{2Ng} P_{x+y}(i) \log\{P_{x+y}(i)\} \quad (3.44)$$

$$Fark\_Varyans = \sum_{i=2}^{2Ng} \left( i - \left[ \sum_{i=2}^{2Ng} iP_{x-y}(i) \right] \right)^2 \quad (3.45)$$

$$Fark\_Entropi = - \sum_{i=0}^{Ng-1} P_{x-y}(i) \log\{P_{x-y}(i)\} \quad (3.46)$$

$$Korelasyon\_Bi\lg i\_Ölçümü = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (3.47)$$

$$HXY = -\sum_i \sum_j P(i, j) \log(P(i, j)) \quad (3.48)$$

$$HXY1 = -\sum_i \sum_j P(i, j) \log(P_x(i)P_y(j)) \quad (3.49)$$

Enerji, Denklem 3.50'deki gibi tanımlanmıştır [25]:

$$ENERJİ = \sum_i \sum_j P(i, j)^2 \quad (3.50)$$

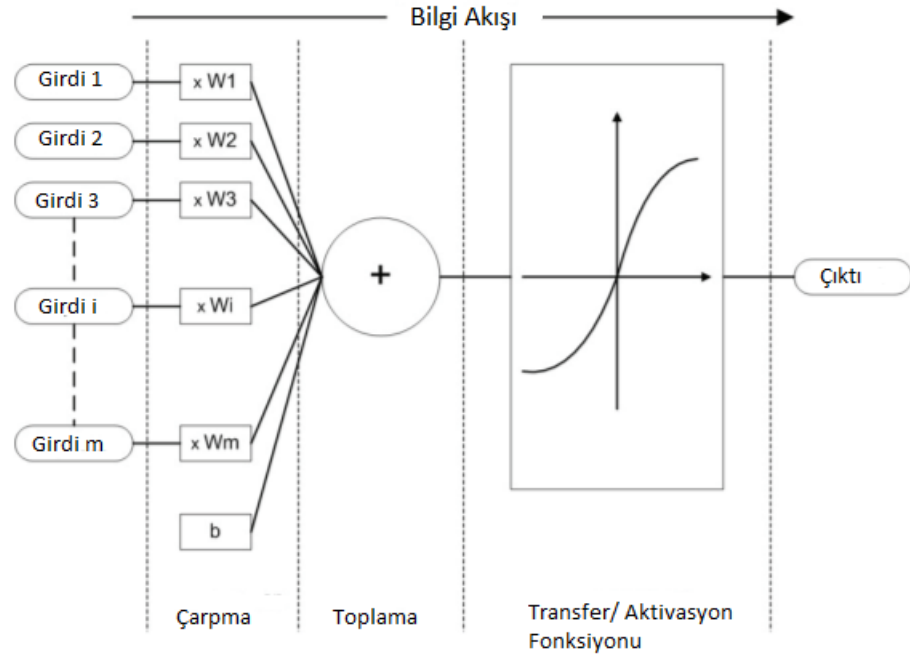
Açısal ikinci moment ve değişmezlik olarak da adlandırılan enerji, bir görüntünün dokusal bütünlüğünün bir ölçüsüdür. Gri seviye dağılımı sabit ya da periyodik bir forma sahip olduğunda enerji en yüksek değere ulaşır. Homojen bir görüntü, çok az baskın gri ton geçişi içerir ve bu nedenle bu görüntü için P matrisinin daha geniş büyüklükte daha az girişe sahip olması, enerji özelliği için büyük bir değere neden olacaktır. Aksine, P matrisinde çok sayıda küçük giriş varsa, enerji özelliği daha küçük bir değere sahip olacaktır.

Entropi, bir görüntünün bozukluğunu/düzensizliğini ölçer ve P matrisindeki tüm elemanlar eşit olduğunda en büyük değerine ulaşır. Görüntü dokusal olarak değişmez olmadığında birçok GSEM elemanı çok küçük değerlere sahiptir, bu da entropinin çok büyük olduğunu gösterir. Bu nedenle, entropi GSEM enerjisi ile ters orantılıdır.

Kontrast, P matrisinin fark momentidir ve görüntüdeki yerel varyasyonların miktarını ölçer [31].

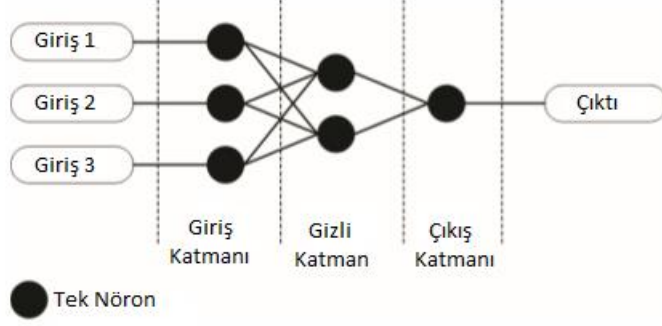
#### 4. YAPAY SINIR AĞLARI

YSA, biyolojik sinir ağlarının yapısını ve işlevlerini simüle etmeye çalışan matematiksel bir modeldir. Her yapay sinir ağının temel yapı taşı, yapay bir nöron, yani basit bir matematiksel modeldir (fonksiyon). Böyle bir modelin üç basit kuralı vardır: çarpma, toplama ve aktivasyon. Şekil 4.1’de gösterildiği gibi yapay nöronun girişindeki girdi değerleri ağırlıklı olarak, her giriş değerinin bireysel ağırlıkla çarpıldığı anlamına gelir. Yapay nöronun orta bölümünde, tüm ağırlıklı giriş değerlerini ve b bias değerini toplayan toplam fonksiyonu bulunur. Yapay sinir hücresinin çıkışında, önceden ağırlıklandırılmış girdilerin ve bias değerinin toplamı, transfer fonksiyonu olarak da adlandırılan aktivasyon fonksiyonundan geçmektedir.



Şekil 4.1. Yapay bir sinir ağının çalışma prensibi [29]

Yapay nöronların çalışma prensipleri ve basit bir dizi kuramı özel bir şey benzemese de, bu modellerin tam potansiyel ve hesaplama gücü, Şekil 4.2’de gösterildiği gibi yapay sinir ağlarına bağlanmaya başlandığında ortaya çıkmaktadır. Bu yapay sinir ağları, karmaşıklığın yalnızca birkaç temel ve basit kuraldan kaynaklanabileceği gerçeğini kullanır.




Şekil 4.2. Basit yapay sinir ağı örneği [29]

Geçmişte, araştırmacılar yapay sinir ağlarının çeşitli “standartlaşmış” topografileriyle ortaya çıkmışlardır. Bu önceden tanımlanmış topografiler, daha kolay, daha hızlı ve daha verimli problem çözme konusunda oldukça önemlidirler. Farklı tipteki yapay sinir ağı topografileri, farklı tipteki problemleri çözmek için uygundur. Verilen problemin türünü belirledikten sonra kullanılacak yapay sinir ağının topolojisine karar verilmeli ve daha sonra topolojinin kendisinin ve parametreleri ile ilgili ayarlar yapılmalıdır. Yapay sinir ağı kullanılmadan önce, verilen problemin türünün nasıl çözüleceği öğretilmelidir. Biyolojik sinir ağları, çevrelerinden aldıkları girdilere dayanarak davranışlarını / tepkilerini öğrenebildikleri gibi yapay sinir ağları da aynısını yapabilir. Üç ana öğrenme paradigması vardır: denetimli öğrenme, denetimsiz öğrenme ve takviye öğrenme. Yapay sinir ağı topografyasını, çözmeye çalışılan problem temel alınarak, benzer öğrenme paradigması seçilmelidir. Öğrenme paradigmaları prensiplerinde farklı olsa da, hepsinin ortak bir yönü vardır; “öğrenme verileri” ve “öğrenme kuralları” (seçilmiş maliyet fonksiyonu) temelinde yapay sinir ağı, giriş sinyallerine uygun olarak doğru çıktı yanıtı elde etmeye çalışmaktadır. Yapay bir sinir ağının topolojisi seçildikten ve topolojinin ayarları yapıldıktan sonra yapay sinir ağı uygun bir davranış öğrendiğinde, verilen problemi çözmek için bu yapay sinir ağı kullanılmaya başlanmaktadır.

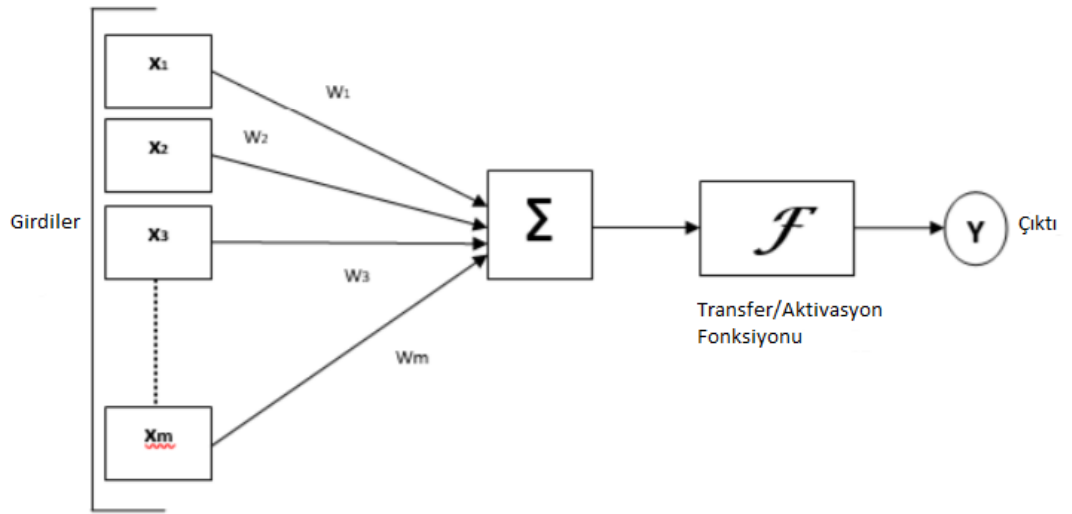
Yapay nöron, her yapay sinir ağının temel yapı taşıdır. Tasarımı ve işlevleri, beyin, omurilik ve çevresel gangliyonları içeren biyolojik sinir ağlarının (sistemler) temel yapı taşı olan biyolojik bir nöronun gözleminden elde edilir. Tasarım ve işlevsellikteki benzerlikler Şekil 4.3'te görülebilir, burada Şekil 4.3'ün sol tarafı soma, dendritleri ve aksonu ile biyolojik bir nöronu temsil eder ve bu şeklin sağ tarafı girdisi, ağırlıkları, bias, transfer fonksiyonu ve çıktı ile yapay bir sinir ağını temsil eder.





Şekil 4.3. Biyolojik ve yapay sinir ağı tasarımı [29]

Biyolojik nöron bilgisi, dendrit yoluyla nörona girdiğinde, soma bilgiyi işler ve akson üzerinden geçirir. Yapay nöron durumunda, bilgi, ağırlıklı olarak girdiler yoluyla yapay bir nöronun gövdesine girer (her bir giriş tek bir ağırlıkla çarpılabilir). Yapay bir nöronun gövdesi, daha sonra, ağırlıklı girdileri, biası toplar ve bir transfer fonksiyonu ile toplamı işleminden geçirir. Sonuçta yapay bir sinir ağı, işlenmiş bilgileri çıktı yoluyla geçirir. Yapay sinir ağı modelinin sadeliği Şekil 4.4'te ve bu şeklin işlenmesi için matematiksel ifade Denklem 4.1'de gösterilmektedir.



Şekil 4.4. Yapay sinir ağı modeli [28]

$$y(k) = F(\sum_{i=1}^m w_i(k) \cdot x_i(k) + b) \quad (4.1)$$

Bu matematiksel ifade;

- $x_i(k)$ , 0'dan m'ye kadar giriş değerleridir.
- $w_i(k)$ , 0'dan m'ye kadar ağırlık değerleridir.
- $b$ , bias değeridir.
- $F$ , transfer/aktivasyon fonksiyonudur.
- $y_i(k)$ , ayrık zaman k cinsinden çıkış değeridir.

Yapay bir sinir ağı modelinde ve Denklem 4.1'de görüldüğü gibi, temel bilinmeyen değişken transfer fonksiyonudur. Transfer fonksiyonu yapay sinir ağının özelliklerini tanımlar ve herhangi bir matematiksel fonksiyon olabilir. Yapay sinir ağının çözmesi gereken problemlerin temelinde transfer fonksiyonu seçilmektedir ve çoğu durumda şu transfer fonksiyonları seçilmektedir: Basamak fonksiyonu, Doğrusal fonksiyon ve Doğrusal olmayan (Sigmoid) fonksiyonu. Basamak fonksiyonu, sadece iki olası çıkış değerine (örneğin sıfır ve bir) sahip ikili bir fonksiyondur. Bu Denklem 4.2'de gösterildiği gibi, giriş değerinin belirli eşiği karşılaması durumunda çıkış değerinin bir değerle sonuçlanması anlamına gelir.


$$y = \begin{cases} 1 & w_i x_i \geq \text{eşik değeri} \\ 0 & w_i x_i < \text{eşik değeri} \end{cases} \quad (4.2)$$

Bu tip transfer fonksiyonu yapay sinir ağında kullanıldığında, bu yapay sinir ağına perceptron denilmektedir. Perceptron, sınıflandırma problemlerini çözmek için kullanılır ve en yaygın olarak yapay sinir ağlarının son katmanında bulunmaktadır. Doğrusal transfer fonksiyonu durumunda yapay sinir ağı, ağırlıklı girişler ve bias toplamı üzerinden basit doğrusal dönüşüm yapmaktadır. Böyle bir yapay sinir ağı, yapay sinir ağlarının giriş katmanında en yaygın olarak kullanılan perceptronun tersidir. Doğrusal olmayan fonksiyon kullanıldığında ise, sigmoid fonksiyonu en yaygın kullanılanıdır. Sigmoid fonksiyonu, yapay sinir ağındaki ağırlık güncellemelerini hesaplarken önemli olabilecek ve kolayca hesaplanan bir türe sahiptir [29].

## 5. UYGULAMA

### 5.1 Veri Seti

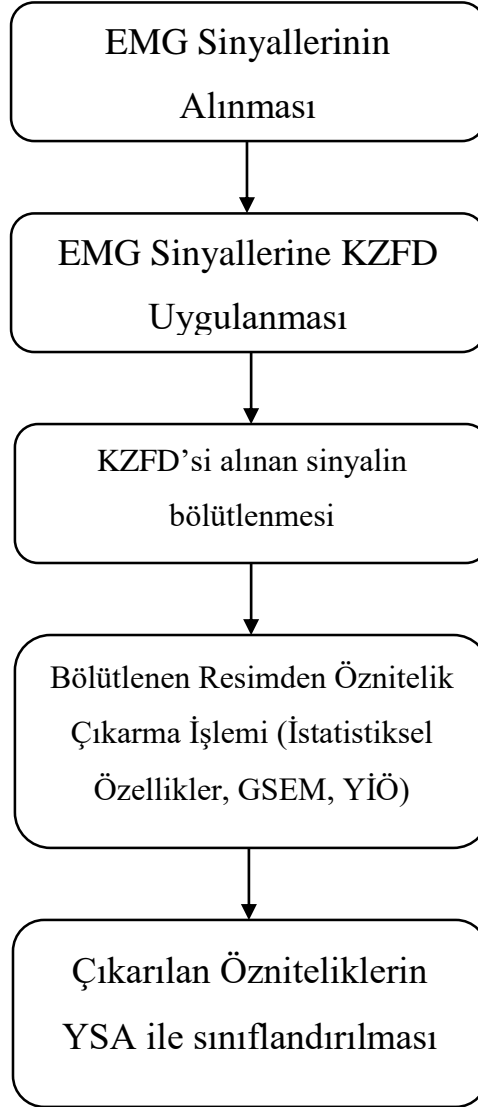
Bu tez çalışmasında UCİ Makine Öğrenmesi veri tabanından hazır olarak alınan veri seti kişilerin farklı nesnelere kavramasından oluşan sinyalleri içermektedir. Ön kola takılan yüzey elektrotları ile bu kavrama hareketlerini tespit etmek amaçlanmıştır. Bir adet sağlıklı erkek bireyden yapılması istenen el hareketleri Şekil 5.1’de gösterilmiştir. Şekil 5.1’de gösterilen 6 hareket; silindirik nesne tutma (A sınıfı), ağır yük tutma (B sınıfı), ince-düz nesnelere tutma (C sınıfı), avuç içine bakacak şekilde nesne kavrama (D sınıfı), küresel nesne tutma (E sınıfı) ve küçük nesne tutma (F sınıfı) hareketleri olarak belirlenmiştir. Hareketler gerçekleştirilirken hareketin deney hızı ve uygulanacak olan kuvvet kişiye bırakılarak tekrarlanması istenmiştir. Yapılması istenen nesne tutma hareketleri 3 gün artarda 5 saniyelik periyotlar ile 100 tekrar edilmiştir ve sonuç olarak her bir harekete ait 300 adet EMG sinyali kaydedilmiştir. Alınan bu EMG sinyallerine 15Hz ile 500Hz arası band geçiren filtre ve 50Hz çentik filtresi gürültüleri temizlemek amacıyla kullanılmıştır [26], [27].



Şekil 5.1. Veri setinde bulunan el hareketleri

## 5.2 Yapılan Çalışma


Bu çalışmada alınan EMG sinyallerinden hareket tespiti amaçlanmıştır. Bu amaçla, alınan EMG sinyallerine KZFD dönüşümü uygulanarak sinyallere ait Zaman-Frekans (Z-F) gösterimleri elde edilmiştir. Daha sonra Z-F gösterimleri normalize edilerek 8 bit gri tonlanmış gösterimlere dönüştürülmüştür. Her bir parçanın sonuca olan etkisini arttırmak amacıyla resim belirli oranda bölünerek alt resimlere bölütlenmiştir. Daha sonra bu her bir alt görüntüden istatistiksel yöntemler, GSEM ve YİÖ yöntemleri kullanılarak görüntülere ait öznitelikler çıkarılmıştır. Son olarak çıkarılan bu öznitelikler YSA kullanılarak sınıflandırılmış ve sistemin başarımı hesaplanmıştır. Yapılan çalışmanın akış diyagramı Şekil 5.2’de gösterilmiş olup tüm adımlar aşağıda detaylı bir şekilde anlatılacaktır.




Şekil 5.2 Önerilen Sistemin çalışma şeması

## 5.2.1 EMG Sinyalinin Alınması


EMG sinyalinin alınan sisteme uygun hale getirilme işlemidir. Her bir sınıfa ait ham EMG sinyali Şekil 5.3'te verilmiştir.




Silindirik Nesne Tutma Hareketi  
(A Sınıfı)




Ağır Yük Tutma Hareketi  
(B Sınıfı)




İnce-Düz Nesne Tutma Hareketi  
(C Sınıfı)



Avuç içi Nesne Tutma Hareketi  
(D Sınıfı)



Küresel Nesne Tutma Hareketi  
(E Sınıfı)




Küçük Nesne Tutma Hareketi  
(F Sınıfı)


Şekil 5.3. Her bir sınıfa ait ham EMG sinyallerinin görüntüleri

### 5.2.2 KZFD Uygulanması


EMG sinyallerinin Z-F düzlemine dönüştürüldükten sonra sinyal ile ilgili daha fazla bilgi içerdiğinden dolayı ham EMG sinyalleri KZFD yöntemi ile Z-F düzlemine aktarılmıştır. Şekil 5.3'te verilen hareketlere ait EMG sinyalinin Z-F düzlemi gösterimi Şekil (5.4 )ve (5.5)'te gösterilmiştir. Z-F düzlemine aktarılan bu gösterimler 1000x160 boyutunda görüntüleri meydana getirmiştir. Daha sonra Z-F düzlemine aktarılan EMG sinyali gösterimleri normalize edilerek 8 bitlik gri tonlanmış gösterimlere dönüştürülmüştür.




Silindirik Nesne Tutma Hareketi  
(A Sınıfı)




Sinyalin Z-F gösterimi




Ağır Yük Tutma Hareketi  
(B Sınıfı)



Sinyalin Z-F gösterimi

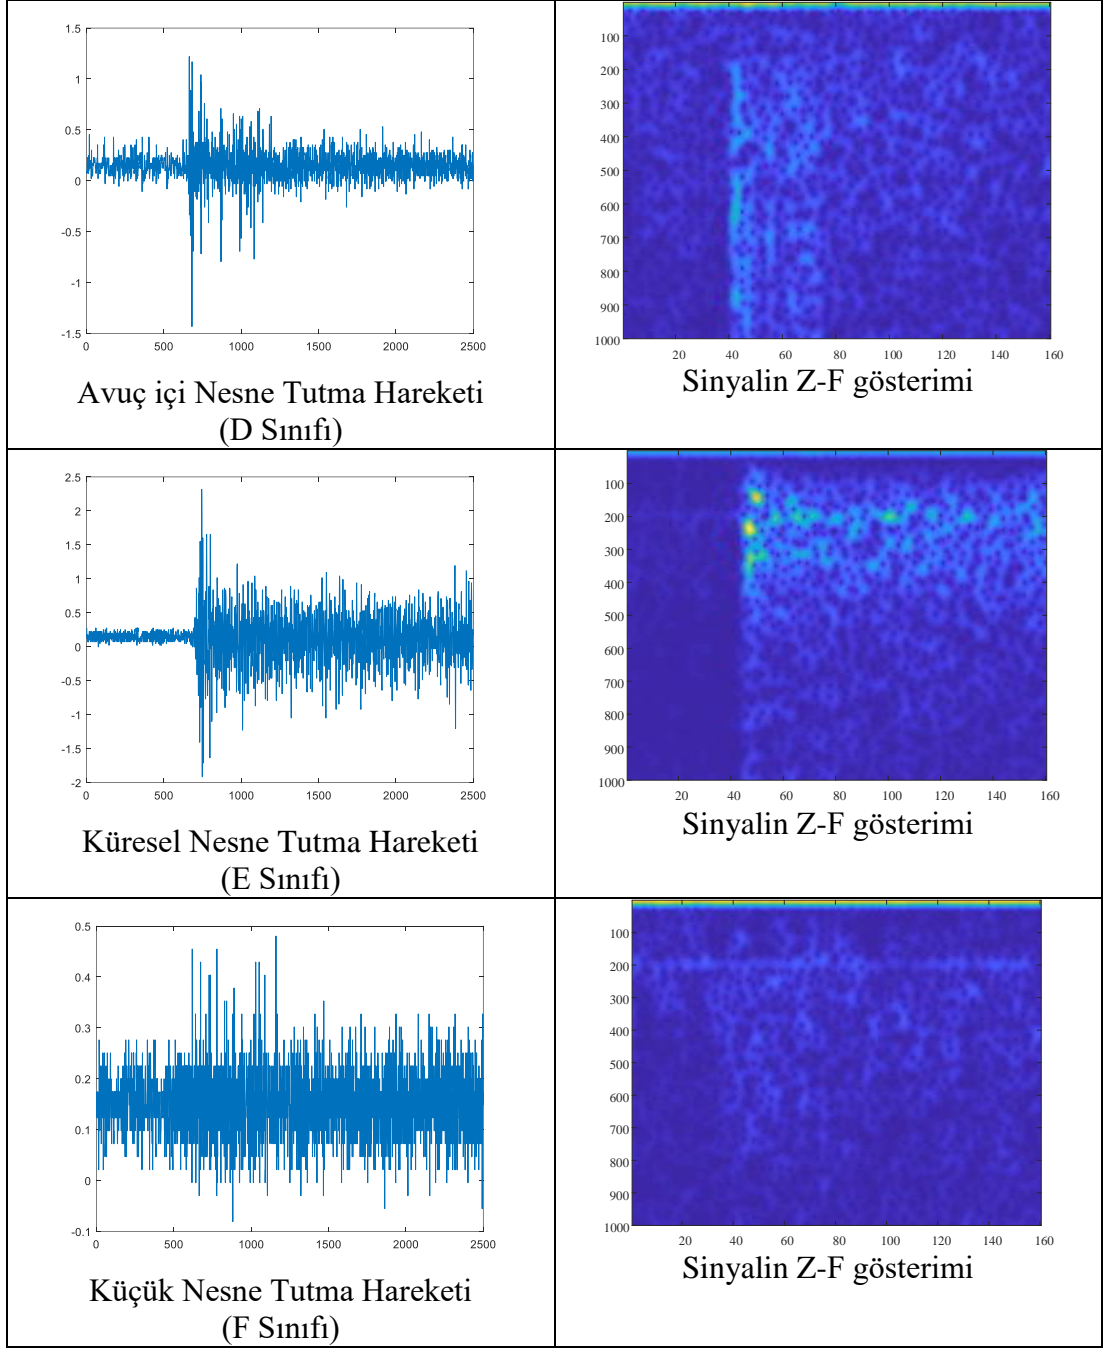


İnce-Düz Nesne Tutma Hareketi  
(C Sınıfı)



Sinyalin Z-F gösterimi

Şekil 5.4. Ham Sinyallerin KZFD yöntemi ile Z-F düzlemine alınması




Şekil 5.5. Ham Sinyallerin KZFD yöntemi ile Z-F düzlemine alınması

### 5.2.3 Z-F Gösterimlerinin Bölütlenmesi

Z-F gösterimleri EMG sinyalleri hakkından çok fazla bilgi içerdiği için KZFD dönüşümü ile Z-F düzlemine aktarılmıştır. Z-F gösterimlerinin sonuca etkisini arttırmak amacıyla Z-F düzlemleri bölütlenmiştir. Bölütlenen bir EMG sinyalinin gösterimi Şekil 5.6'da verilmiştir. Z-F düzleminde bulunan 1000\*160 boyutundaki



görüntüler, 100\*160 boyutunda alt görüntülere bölütlenmiştir. Böylelikle her bir görüntüden 10 adet bölütlenmiş alt resim elde edilmiştir. Gösterimin rahat anlaşılması için Şekil 5.6'da bir resim üzerinde bu bölütleme gösterilmiştir.



Şekil 5.6. Z-F gösteriminin bölütlenmesi

#### 5.2.4 Öznitelik Çıkarılması

100x160 boyutunda bölütlenen her bir Z-F gösterimlerinden istatistiksel yöntemler ile 3 adet, GSEM ile 9 adet ve YİÖ ile 8 komşuluktan gelen 59 adet öznitelikle birlikte toplam 71 adet öznitelik çıkarılmıştır. Her bir görüntüden 10 tane alt görüntü olduğu için bir EMG sinyaline ait Z-F gösteriminden 710 adet öznitelik çıkarılmıştır.

#### 5.2.5 YSA ile Sınıflandırma

Ham sinyallerinden KZFD dönüşümü ile Z-F düzlemine alınan sinyallerden istatistiksel yöntemler, GSEM ve YİÖ yöntemleri ile çıkarılan öznitelikler YSA'ya giriş verisi olarak verilmiştir. Her bir harekete ait 300 adet kayıt olduğu için ve toplamda 6 sınıf olduğu için toplamda 1800 adet EMG sinyalinin her birine ait 710 adet öznitelik çıkarılmıştır.

Yapılan çalışmaların yürütüldüğü bilgisayar, 3.50GHz işlemci ve 8 GB bellek özelliklerine sahiptir. Deneysel çalışma MATLAB ortamında yapılmıştır.

### 5.3 Sonuçlar

Yapılan çalışmada öncelikler 2 sınıflar olacak şekilde EMG sinyalleri sınıflandırılmış ve daha sonra tüm sınıflar sınıflandırılarak sistemin doğruluk başarımı hesaplanmıştır. Çizelge 5.1’de 2 sınıflı sınıflandırmada kullanılan YSA modelinin parametreleri verilmiştir. Tüm veriler için aynı parametreler kullanılmıştır. Çalışmada verilerin %80’i (480 adet sinyal) eğitim, %20’si (120 adet sinyal) test için kullanılmıştır.

*ROC eğrisi*, doğru pozitiflerden oluşan dikey ve yanlış pozitiflerden oluşan yatay eksen oranlarının yer aldığı eğridir.

Doğru pozitif oranı ne kadar yüksekse sonuçlar başarılı, yanlış pozitif oranı fazla ise sistem başarısız kabul edilir. Diğer bir deyişle ROC eğrisinin altında kalan alan ne kadar büyük ise sistemin doğruluğu o kadar fazladır.

Başarımların değerlendirilmesinde daha iyi karar verebilmek amacıyla duyarlılık ve özgüllük performans kriterleri de kullanılarak sonuçları sunulmuştur.

$$\text{Duyarlılık} = \text{Duyarluluk} = \frac{DP}{(DP+YN)} \quad (5.1)$$

$$\text{Özgüllük} = \frac{FN}{(DN+YP)} \quad (5.2)$$

Hesaplama yapılırken, DP Doğru Pozitifleri, DN Doğru Negatifleri, YP Yanlış Pozitifleri ve YN Yanlış Negatifleri ifade etmektedir.

Çizelge 5.1. İki sınıf için tasarlanan YSA modelinin özellikleri

Katman Sayısı	3
Katmanlardaki nöron sayısı	Giriş: 710 Gizli: 30 Çıkış: 2
Başlangıç ağırlıkları ve Bias Değerleri	Rastgele
Aktivasyon Fonksiyonu	Tanjant-sigmoid / Lineer
Eğitim Parametreleri	
Öğrenme kuralı	Scaled Conjugate Gradient
Toplam Karesel Hata	0.0000001

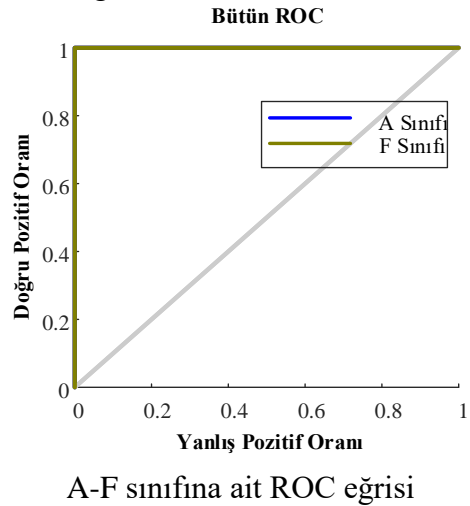
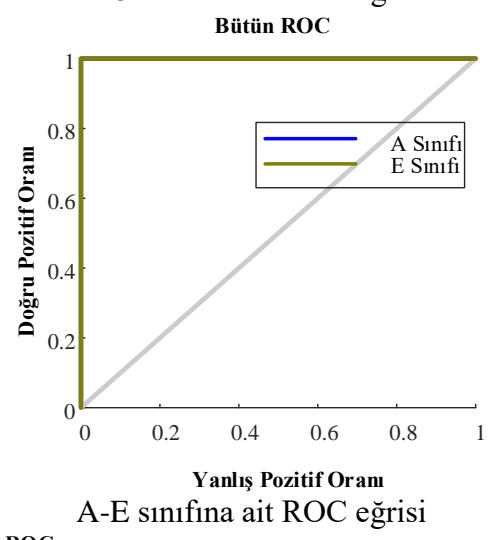
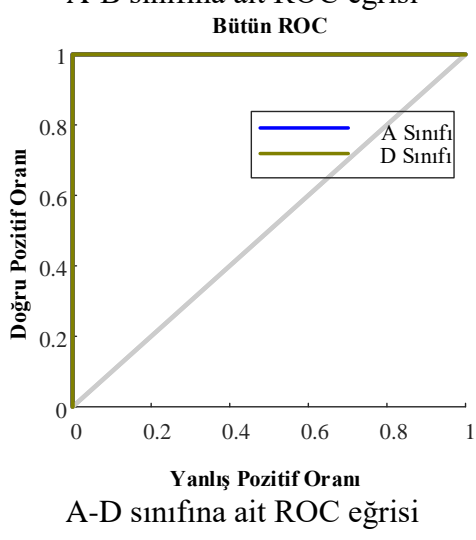

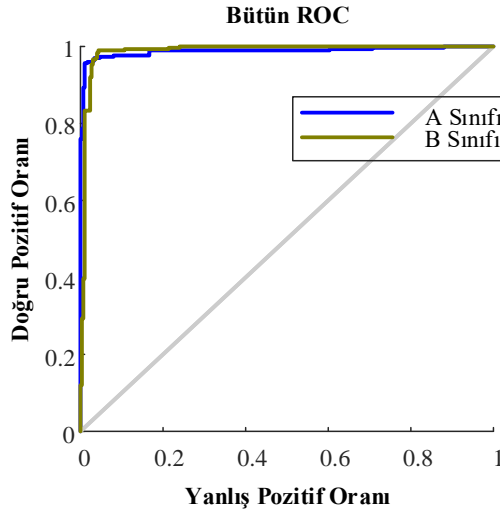
A sınıfı sırasıyla B,C,D,E ve F sınıfları ile ayrı ayrı sınıflandırılmış ve sınıflandırma doğruluk başarımı Çizelge 5.2’de verilmiştir. Sınıflandırma işlemine ait duyarlılık ve özgüllük değerleri Çizelge 5.3’te, ROC eğrileri ise Şekil 5.7’de verilmiştir.

Çizelge 5.2. A sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı

Sınıf Sayısı	Sınıf İsimleri	Sınıflandırma Doğruluk Başarısı (maximum)
2	A-B	%97.7
2	A-C	%100
2	A-D	%100
2	A-E	%100
2	A-F	%100

Çizelge 5.3. A sınıfı ile diğer sınıflara ait performans sonuçları

Sınıf İsimleri	Duyarlılık	Özgüllük
A-B	%91	%92.5
A-C	%100	%100
A-D	%100	%100
A-E	%100	%100
A-F	%100	%100



Şekil 5.7. A-B,C,D,E,F sınıflarına ait ROC eğrisi


B sınıfı sırasıyla C,D,E ve F sınıfları ile ayrı ayrı sınıflandırılmış ve sınıflandırma doğruluk başarımı Çizelge 5.4’te verilmiştir. Sınıflandırma işlemine ait duyarlılık ve özgülük değerleri Çizelge 5.5’te, ROC eğrileri ise Şekil 5.8’de verilmiştir.

Çizelge 5.4. B sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı

Sınıf Sayısı	Sınıf İsimleri	Sınıflandırma Doğruluk Başarısı (maximum)
2	B-C	%99.5
2	B-D	%100
2	B-E	%100
2	B-F	%99.7

Çizelge 5.5. B sınıfı ile diğer sınıflara ait performans sonuçları

Sınıf İsimleri	Duyarlılık	Özgüllük
B-C	%98.3	%100
B-D	%100	%100
B-E	%100	%100
B-F	%100	%98.3



Şekil 5.8. B- C,D,E,F sınıflarına ait ROC eğrisi

C sınıfı sırasıyla D,E ve F sınıfları ile ayrı ayrı sınıflandırılmış ve sınıflandırma doğruluk başarımları Çizelge 5.6’da verilmiştir. Sınıflandırma işlemine ait duyarlılık ve özgüllük değerleri Çizelge 5.7’de, ROC eğrileri ise Şekil 5.9’da verilmiştir.

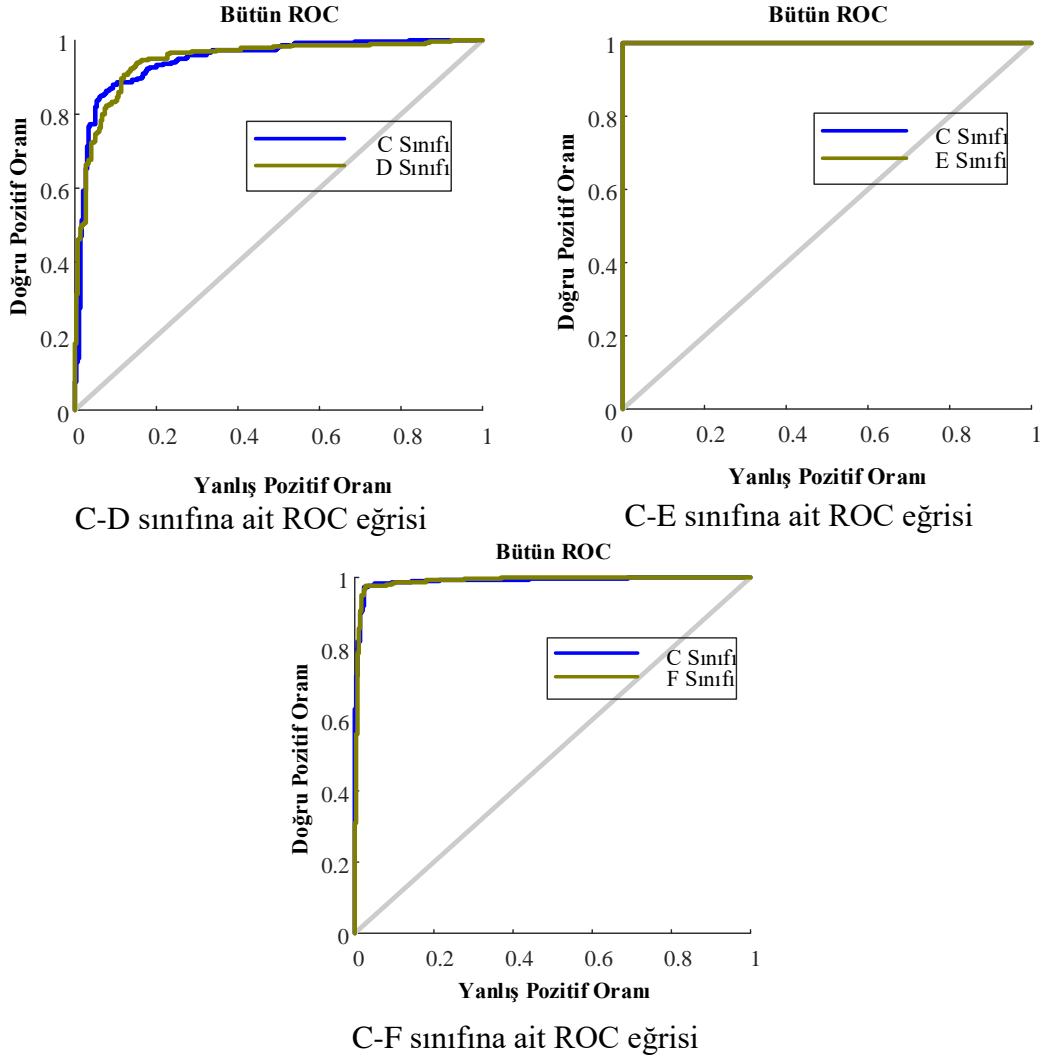
Çizelge 5.6. C sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarıları

Sınıf Sayısı	Sınıf İsimleri	Sınıflandırma Doğruluk Başarısı (maximum)
2	C-D	%89.5
2	C-E	%100
2	C-F	%96.3

Çizelge 5.7. C sınıfı ile diğer sınıflara ait performans sonuçları

Sınıf İsimleri	Duyarlılık	Özgüllük
C-D	%79	%63.7
C-E	%100	%100
C-F	%85.7	%93





Şekil 5.9. C-D,E,F sınıflarına ait ROC eğrisi

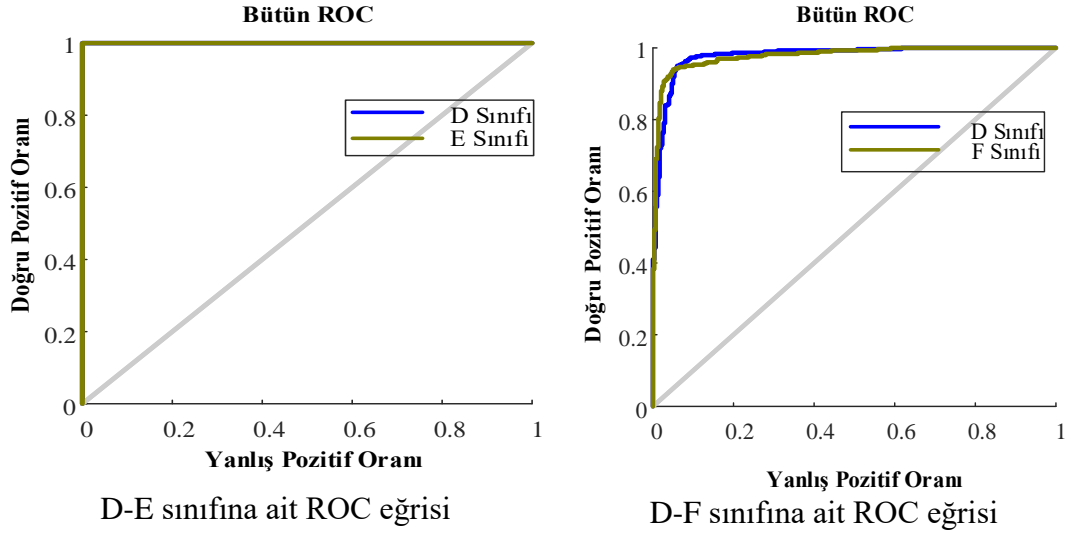
D sınıfı sırasıyla E ve F sınıfları ile ayrı ayrı sınıflandırılmış ve sınıflandırma doğruluk başarımı Çizelge 5.8’de verilmiştir. Sınıflandırma işlemine ait duyarlılık ve özgüllük değerleri Çizelge 5.9’da, ROC eğrileri ise Şekil 5.10’da verilmiştir.

Çizelge 5.8. D sınıfı ile diğer sınıflara ait sınıflandırma doğruluk başarısı

Sınıf Sayısı	Sınıf İsimleri	Sınıflandırma Doğruluk Başarısı (maximum)
2	D-E	%100
2	D-F	%94.2

Çizelge 5.9. D sınıfı ile diğer sınıflara ait performans sonuçları

Sınıf İsimleri	Duyarlılık	Özgüllük
D-E	%100	%100
D-F	%91	%77



Şekil 5.10. D-E,F sınıflarına ait ROC eğrisi

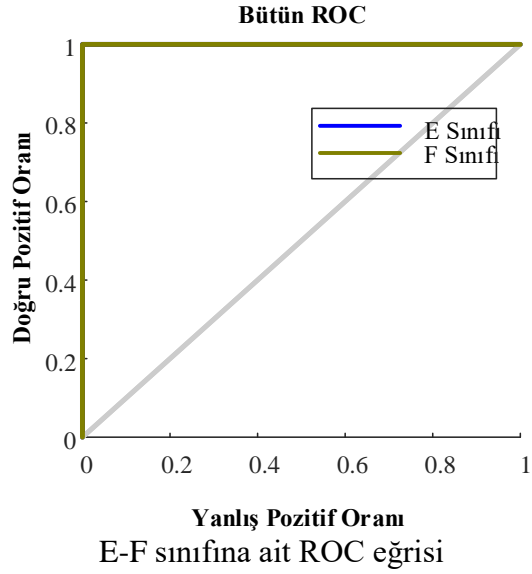
E sınıfı F sınıfı ile sınıflandırılmış ve sınıflandırma doğruluk başarımı Çizelge 5.10'da verilmiştir. Sınıflandırma işlemine ait duyarlılık ve özgüllük değerleri Çizelge 5.11'de, ROC eğrileri ise Şekil 5.11'de verilmiştir.

Çizelge 5.10. E sınıfı ile F sınıfına ait sınıflandırma doğruluk başarısı

Sınıf Sayısı	Sınıf İsimleri	Sınıflandırma Doğruluk Başarısı (maximum)
2	E-F	%100

Çizelge 5.11. E sınıfı ile F sınıfına ait performans sonuçları

Sınıf İsimleri	Duyarlılık	Özgüllük
E-F	% 100	% 100




Şekil 5.11. E,F sınıflarına ait ROC eğrisi

Yapılan çalışmada bulunan bütün sınıflar YSA’da sınıflandırılarak sistemin başarımlı hesaplanmıştır. Kullanılan YSA modelinin özellikleri Çizelge 5.12’de verilmiştir. Çalışmanın sonucunda sınıflandırma doğruluk başarımlı maksimum %93 olarak ortalama başarımlı ise %92 olarak hesaplanmıştır. Sistemin ROC eğrisi ise Şekil 5.12’de verilmiştir.

Çizelge 5.12. Altı sınıf için tasarlanan YSA modelinin özellikleri

Katman Sayısı	3
Katmanlardaki nöron sayısı	Giriş: 710 Gizli: 30 Çıkış: 6
Başlangıç ağırlıkları ve Bias Değerleri	Rastgele
Aktivasyon Fonksiyonu	Tanjant-sigmoid Lineer
Eğitim Parametreleri	
Öğrenme kuralı	Scaled Conjugate Gradient
Toplam Karesel Hata	0.0000001



Şekil 5.12. Bütün sınıflara ait ROC eğrisi

Önerilen yöntemin performans değerlendirmesinin daha iyi yapılabilmesi amacıyla yapılan çalışmada kullanılan veri setini kullanan [26]'nolu çalışma ile kıyaslanmıştır. [26]'nolu çalışmada EMG sinyalinden hareket tespiti amacıyla ham sinyal ve ham sinyalin karakök ortalama değerlerini ayrı ayrı hesaplamışlardır.

Hesaplanan bu deęerler Radyal Taban Fonksiyon, Sıralı Minimal Optimizasyon ve En Küçük Kareler yöntemleri ile sınıflandırmışlardır. Daha sonra sınıflandırma sonucunda çıkan doğruluk oranları kıyaslanmıştır. Başarım karşılaştırmaları Çizelge 5.13'te sunulmuştur.

Çizelge 5.13. Önerilen yöntemin mevcut yöntemler ile doğruluk oranlarının karşılaştırılması

Yöntem	Ortalama Doğruluk Oranı Tüm Sınıflar için
Sapsanis C.	% 80
Önerilen yöntem	% 93

Çizelge 5.13'te görüldüğü üzere önerilen yöntemin doğruluk başarımı karşılaştırılan yöntemden daha iyi bir sınıflandırma başarımı sağlamıştır. Bu veriler ışığında önerilen yöntemin EMG sinyallerinin sınıflandırılmasında etkin bir şekilde kullanılabileceği görülmektedir.

Tüm veri setleri eğitilip doğruluk oranları hesaplanmıştır çalışma sonucunda hesaplanan başarım oranları Çizelge 5.14'te verilmiştir.

Çizelge 5.14. Tüm sisteme ait Sınıflandırma Doğruluk Başarısı

Sınıf Sayısı	Sınıf İsimleri	Sınıflandırma Doğruluk Başarısı (maximum)
2	A-B	%97.7
2	A-C	%100
2	A-D	%100
2	A-E	%100
2	A-F	%100
2	B-C	%99.5
2	B-D	%100
2	B-E	%100
2	B-F	%99.7
2	C-D	%89.5
2	C-E	%100
2	C-F	%96.3
2	D-E	%100
2	D-F	%94.2
2	E-F	%100
6	A-B-C-D-E-F	%93

## 6. SONUÇLAR VE DEĞERLENDİRME

EMG sinyallerinden hareket tespiti protez kol çalışmaları için ön hazırlık olarak söylenebilir. Bu yüzden EMG sinyallerinden doğru başarıım oranı ile hareket tespit edilmesi istenmektedir. Yapılan çalışmada da EMG sinyallerinden hareket tespiti üzerine çalışılmıştır.

Bu amaçla öncelikle EMG sinyallerine KZFD uygulanarak Z-F gösterimleri elde edilmiştir. Çıkarılan bu Z-F gösterimlerinin sonuca etkisini arttırmak amacıyla bu gösterimler bölütlenerek alt gösterimleri elde edilmiştir. Daha sonra elde edilen alt gösterimlerden özellik çıkarmak amacıyla istatistiksel yöntemler, GSEM ve YİÖ yöntemleri kullanılarak EMG sinyallerine ait öznelikler çıkarılmıştır. Çıkarılan bu öznelikle YSA ile sınıflandırılarak sistemin iki sınıflı ve altı sınıflı olacak şekilde sınıflandırma oranları hesaplanmıştır. Önerilen yöntemde sinyal Z-F düzlemine dönüştürülerek zamanın sinyale olan etkisi göz önünde bulundurulması amaçlanmıştır. Yapılan çalışmada literatürde çok fazla kullanılan iki sınıflı sistem tasarlanmış ve tasarlanan sistemin başarıım oranının genel olarak yüksek olduğu gözlemlenmiştir. Altı sınıflı sistemin başarıımı ise [26]'nolu çalışmanın bulmuş olduğu sonuçlar ile kıyaslandığında daha iyi sonuç verdiği görülmüştür.

Sınıflandırma sonrasında elde edilen sonuçlar başarı oranı olarak iyi sonuç verdiği gözlemlenmiştir. Sonuçlara bakılarak ileride yapılabilecek protez kol çalışmalarında ve hareket tespiti uygulamalarında uygulanabilir olabileceği gözlemlenmiştir.

## 7. KAYNAKLAR

- [1] J. R. Cram, *The history of surface electromyography*, **Appl. Psychophysiol. Biofeedback**, 28:2 (2003) 81–91.
- [2] M. B. I. Reaz, M. S. Hussain and F. Mohd-Yasin, *Techniques of EMG signal analysis: Detection, processing, classification and applications*, **Biol. Proced. Online**, 8:1 (2006) 11–35.
- [3] E. Abel, P. Zacharia, A. Forster and T. Farrow, *Neural network analysis of the EMG interference pattern*, **Med. Eng**, 1 (1996) 12–17.
- [4] C. Christodoulou and C. S. Pattichis, Combining neural classifiers in EMG diagnosis, 6th Eur. Congr. Intell. Tech. Soft Comput. EUFIT '98, 3 (1998) 1837–1841.
- [5] C. I. Christodoulou and C. S. Pattichis, *Unsupervised pattern recognition for the classification of EMG signals*, **IEEE Trans. Biomed. Eng.**, 46:2 (1999) 169–78.
- [6] N. F. Güler and S. Koçer, *Classification of EMG signals using PCA and FFT*, **J. Med. Syst.**, 29:3 (2005) 241–250.
- [7] A. Subasi, M. Yilmaz and H. R. Ozcalik, *Classification of EMG signals using wavelet neural network*, **J. Neurosci. Methods**, 156:1–2 (2006) 360–367.
- [8] E. M. Tamil, N. S. Bashar, M. Y. I. Idris and A. M. Tamil, *A review on feature extraction & classification techniques for biosignal processing (Part III: Electromyogram)*, **IFMBE Proc.**, 21:1 (2008) 117–121.
- [9] L. Shaw and S. Bagha, *Online Emg Signal Analysis for Diagnosis of Neuromuscular Diseases By Using Pca and Pnn*, **Int. J. Eng. Sci.**, 4:10 (2012) 4453–4459.
- [10] A. Subasi, *Classification of EMG signals using combined features and soft computing techniques*, **Appl. Soft Comput. J.**, 12:8 (2012) 2188–2198.
- [11] A. Subasi, *Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders*, **Comput. Biol. Med.**, 43:5 (2013) 576–586.
- [12] A. Phinyomark, F. Quaine, S. Charbonnier, C. Serviere, F. Tarpin-Bernard and Y. Laurillau, *EMG feature evaluation for improving myoelectric pattern recognition robustness*, **Expert Syst. Appl.**, 40:12 (2013) 4832–4840.
- [13] A. Prof, M. Tafhim and P. P. Kshirsagar, *A Review on EMG Signal*



- Classification for neurological disorder using neural network*, **IOSR J. Elect. Electro. Eng.**, (2014) 21–23.
- [14] M. Ariyanto, W. Caesarendra, K. A. Mustaqim, M. Irfan, J. A. Pakpahan, J. D. Setiawan and A.R Winoto et al., Finger movement pattern recognition method using artificial neural network based on electromyography (EMG) sensor, 2015 Int. Conf. Autom. Cogn. Sci. Opt. Micro Electro-Mechanical Syst. Inf. Technol. (ICACOMIT), Bandung, Indonesia, 29-30 Oct., (2015) 12–17.
- [15] S. M. Mane, R. A. Kambli, F. S. Kazi and N. M. Singh, *Hand motion recognition from single channel surface EMG using wavelet & artificial neural network*, **Procedia Comput. Sci.**, 49:1 (2015) 58–65.
- [16] G. A. Torres and V. H. Benitez, Finger movements classification from grasping spherical objects with surface electromyography using time domain based features, 2016 IEEE Conf. Mechatronics, Adapt. Intell. Syst. Systems (MAIS 2016), Sonora, Mexico, 20-22 Oct., (2016).
- [17] R. Raj, R. Rejith and K. S. Sivanandan, *Real Time Identification of Human Forearm Kinematics from Surface EMG Signal Using Artificial Neural Network Models*, **Procedia Technol.**, 25 (2016) 44–51.
- [18] D. Yang, W. Yang, Q. Huang and H. Liu, *Classification of Multiple Finger Motions during Dynamic Upper Limb Movements*, **IEEE J. Biomed. Heal. Informatics**, 21:1 (2017) 134–141.
- [19] S. K. Powers and E. T. Howley, *Exercise Physiology*, Mc Grew-Hill, 1994.
- [20] Selda Uzun, *Fatigue Related EMG Power Spectrum Changes During Dynamic Contractions in Female Rowers*, Master Thesis, Boğaziçi University Turkey, 2002.
- [21] R. Begg, D. Lai and M. Palaniswami, *Computational intelligence in biomedical engineering*. 2007.
- [22] A. J. McComas, *Skeletal Muscle: Form and Function*. Champaign, IL : Human Kinetics, CRC Press, 1996.
- [23] A. Ari and D. Hanbay, Detection of Brain Tumor from the MR Images by Using Hybrid Features, Int. Conf. Nat. Sci. Eng. (ICNASE'16), Kilis, Turkey, 19-20 March, (2016).
- [24] R. M. Haralick, K. Shanmugam and I. Dinstein, *Textural features for image classification*, **IEEE Trans. Syst. Man Cybern.**, 1-3 (1973) 610–621.
- [25] L. K. Soh and C. Tsatsoulis, *Texture analysis of sar sea ice imagery using gray*

- level co-occurrence matrices*, **IEEE Trans. Geosci. Remote Sens.**, 37:2 (1999) 780–795.
- [26] Christos Sapsanis, *Recognition of basic hand movements using electromyography*, University of Patras, 2013.
- [27] C. Sapsanis, G. Georgoulas, A. Tzes and D. Lymberopoulos, Improving EMG based classification of basic hand movements using EMD, Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS, Osaka, Japan, 3-7 July, (2013) 5754–5757.
- [28] Anonymous (2018), [https://www.tutorialspoint.com/artificial\\_neural\\_network/](https://www.tutorialspoint.com/artificial_neural_network/) (Son Erişim Tarihi: 18 Temmuz 2018).
- [29] A. Krenker, J. Bester and A. Kos, *Introduction to the Artificial Neural Networks*, Ljubljana, Slovenia, 2011, 1-17.
- [30] Di Huang, C. Shan, M. Ardebilian, Y. Wang and L. Chen, *Local Binary Patterns and Its Application to Facial Image Analysis: A survey*, **IEEE RFIC Virt. J.**, 41:6 (2011) 765-781.
- [31] A. Eleyan and H. Demirel, *Co-occurrence matrix and its statistical features as a new approach for face recognition*, **Turk J Elec Eng Comp Sci**, 19:1 (2011) 97-107.
- [32] Anonymous (2018), <https://www.reed.edu/physics/courses/Physics331.f08/pdf/Fourier.pdf>, (Son Erişim Tarihi: 18 Temmuz 2018).
- [32] Anonymous (2018), <https://www.d.umn.edu/~skatsev/Phys5053/WaveletHelp.pdf>, (Son Erişim Tarihi: 18 Temmuz 2018).
- [33] Anonymous (2018), <https://www.research.cs.tamu.edu/prism/lectures/sp/16.pdf>, (Son Erişim Tarihi: 18 Temmuz 2018).
- [34] Esra Demren, *Dalgacık Dönüşümünün Fourier Dönüşümü ile Karşılaştırılması ve Uygulama*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Türkiye, 2015.

## ÖZGEÇMİŞ

**Adı Soyadı:** Furkan AYZ

**Doğum Yeri ve Tarihi:** Malatya - 1992

**Adres:** Tandoğan Mahallesi, Kavak Caddesi Yakamoz Evleri 2 Sitesi B-Blok  
Battalgazi/Malatya

**E-Posta:** [furkanayaz44@gmail.com](mailto:furkanayaz44@gmail.com)

**Lisans:** Çukurova Üniversitesi Bilgisayar Mühendisliği Bölümü (2010-2015)

### Tezden Türetilen Yayınlar/Sunumlar

- F. Ayaz, A. Ari, D. Hanbay, Yapay Sinir Ağı Tabanlı EMG Sinyallerin Sınıflandırılması, International Conference on Artificial Intelligence and Data Processing (IDAP), Malatya, Türkiye, 2016.