

**OMUZ EGZERSİZLERİNİN RGB-D VERİSİ  
KULLANILARAK GERÇEK ZAMANLI KESTİRİMİ İÇİN  
SANAL EGZERSİZ SİSTEMİ**

**VIRTUAL TRAINING FRAMEWORK FOR SHOULDER  
EXERCISES WITH REAL-TIME RECOGNITION FROM  
RGB-D DATA**

**VOLKAN ULUTAŞ**

**Dr. Öğr. Üyesi Ufuk ÇELİKCAN**  
**Tez Danışmanı**

Hacettepe Üniversitesi  
Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliğinin  
Bilgisayar Mühendisliği Anabilim Dalı İçin Öngördüğü  
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2019

Volkan ULUTAŞ'ın hazırladığı “Omuz Egzersizlerinin RGB-D Verisi Kullanılarak Gerçek Zamanlı Kestirimi İçin Sanal Egzersiz Sistemi” adlı bu çalışma aşağıdaki jüri tarafından **BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Haşmet GÜRÇAY

Başkan

  
.....

Dr. Öğr. Üyesi Ufuk ÇELİKCAN

Danışman

  
.....


Prof. Dr. Pınar DUYGULU ŞAHİN

Üye

  
.....

Prof. Dr. Tolga Kurtuluş ÇAPIN

Üye

  
.....

Dr. Öğr. Üyesi Elif SÜRER

Üye

  
.....

Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK TEZİ** olarak ... / ... / ..... tarihinde onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

*Anne ve Babama...*

## ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

18 / 09 / 2019



VOLKAN ULUTAŞ

## YAYINLAMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan "**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**" kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
- Enstitü Fakülte yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren .... ay ertelenmiştir.
- Tezim ile ilgili gizlilik kararı verilmiştir.

18 / 09 / 2019

  
VOLKAN ULUTAŞ

## ÖZET

# OMUZ EGZERSİZLERİNİN RGB-D VERİSİ KULLANILARAK GERÇEK ZAMANLI KESTİRİMİ İÇİN SANAL EGZERSİZ SİSTEMİ

**VOLKAN ULUTAŞ**

**Yüksek Lisans, Bilgisayar Mühendisliği Bölümü**

**Tez Danışmanı: Dr. Öğr. Üyesi Dr. Ufuk ÇELİKCAN**

**Eylül 2019, 116 sayfa**

Omuz ağrısı ve rahatsızlık çok yaygın olarak görülen ve ciddi problemlerdir. Omuz tedavisi yapılandırılmış ve tekrarlayan bir programdan yararlanır. Geleneksel fiziksel rehabilitasyon programlarında, hastalar sıklıkla fizyoterapistin hareketi öğretmesine tabi aralıklı geri bildirim ile egzersiz yaparlar. Bununla birlikte, evde yapılan rehabilitasyonda, hasta fizyoterapist tarafından herhangi bir geri bildirim almamaktadır. Bu, tedavi sürecinde kesintiye, yanlış tedaviye ve hatta kendi kendine yaralanmasına neden olabilir. Bu çalışma, Omuz Terapileri için Sanal Egzersiz Sistemi (ViTES), bağlılığı artırıcı terapi uygulamaları ve omuz rehabilitasyonu için hasta motivasyonunu sağlamak için umut verici yeni bir araç olarak önerilmektedir. ViTES, kullanıcıları eğitebilir ve gelen RGB-D veri akışından gerçek zamanlı tanıma ile eş zamanlı olarak egzersiz performanslarını değerlendirebilir. Çalışma kapsamında ViTES ile kullanılan öğrenme modelini oluşturmak için V-Shoulder veriseti de oluşturuldu. Veri seti, toplam 7 farklı omuz tedavisi egzersizinin 739 egzersiz örneğinden oluşmakta ve Kinect RGB-D sensörü kullanılarak oluşturulmuştur. ViTES'in kullanılabilirliğini ve etkinliğini iki bölümden oluşan bir kullanıcı çalışması ile doğrulanmıştır. Kullanıcıların ViTES'i kısa bir anket aracılığıyla değerlendirdiği birinci bölümde, sistem tüm kullanıcılardan olumlu görüşler almasına ek olarak kullanıcılar sistemin kullanımının kolay olduğu bildirimini vermiştir. İkinci bölümde, V-Shoulder verisetinden öğrenilen veri madenciliği modeline göre, ViTES tarafından otomatik olarak analiz edilen omuz egzersiz hareketlerinin benzer-

liklerini karşılaştırıldı. Sonuçlar, ViTES'in geleneksel fizyoterapi sürecini tamamlamada yararlı bir araç olma konusunda dikkate değer bir potansiyele sahip olduğunu göstermektedir.

**Anahtar Kelimeler:** İnsan Hareket Tanıma; Veri Madenciliği; Omuz Egzersiz Hareketlerinin Sınıflandırılması; RGB-D Hareketlerinden öznitelik çıkartılması; Sanal Egzersiz Sistemi, Destek Vektör Makinaları; K-En Yakın Komşu Algoritması; Karar Ağaçları; Yapay Sinir Ağları; Ensemble Learning Methods.

## **ABSTRACT**

### **VIRTUAL TRAINING FRAMEWORK FOR SHOULDER EXERCISES WITH REAL-TIME RECOGNITION FROM RGB-D DATA**

**VOLKAN ULUTAŞ**

**Master of Science, Department of  
Computer Engineering**

**Supervisor: Dr. Öğr. Üyesi Dr. Ufuk ÇELİKCAN**

**September 2019, 116 pages**

Shoulder pain and discomfort are common and serious problems. Shoulder treatment benefits from a structured and repetitive program. In traditional physical rehabilitation programs, patients frequently perform exercises with intermittent feedback following the demonstrations from the physiotherapist. However, with at-home rehabilitation, the patient does not receive feedback after the initial demonstrations. This may lead to interruption in the treatment process, improper treatment and even self-inflicted injuries. This work propose Virtual Training Environment for Shoulder Exercises (ViTES) as a promising new tool to achieve sustained therapy practice and patient motivation for shoulder rehabilitation. ViTES can train users and assess their exercise performance concurrently with real-time recognition from incoming RGB-D data stream. To create the learning model that we use with ViTES, we also created V-Shoulder Dataset. The dataset consists of 739 exercise samples of 7 different shoulder treatment exercises in total and was created using Kinect RGB-D sensor. We validated the usability and the efficacy of ViTES by a two-part user study. In the first part, where the users evaluated ViTES via a short questionnaire, it was seen that all users regarded the system positively and found it easy to use. In the second part, we compared the similarities of the exercise movements performed by the users as automatically assessed by ViTES with respect to the model learned from the V-Shoulder Dataset. The results show that ViTES has a remar-



kable potential to be a beneficial tool in complementing the traditional physiotherapy process.

**Keywords:** Human Motion Recognition; Data Mining; Classification of Shoulder Exercise Motions, Feature Extraction from RGD-D motion; Support Vector Machine; Virtual Training Environment for Shoulder Exercises; K-Nearest Neighbours; Decision Tree; Multilayer Perceptron, Topluluk Öğrenmesi Yöntemleri.

## TEŐEKKÜR

İlk olarak, tez konusunun belirlenmesinde ve tez alıőmaları sűrecinde birikim ve tecrűbeleriyle bana yol gűsterici olan ek olarak gűsterdiđi anlayıő ve sabır dolayısıyla danıőmanım Sayın Dr. Őđr. Őyesi Ufuk ELİKCAN'a teőekkűr ederim.

Tezim sűrecinde, veri seti oluőturma, tez konusunun belirlenmesi ile fizyoterapi ve rehabilitasyon alanındaki deđerli yűnlendirmelerinden dolayı Do. Dr. İrem DŪZGŪN'e teőekkűrlerimi sunarım.

Bu tez alıőmasında, Hacettepe Őniversitesi Fizyoterapi ve Rehabilitasyon Bűlűmű Őđretim gűrevlilerinin destekleriyle omuz rehabilitasyon hareketleri iin RGB-D veri seti oluőturulmuőtur. Desteklerinden dolayı tűm bűlűm akademik alıőanlarına adına bűlűm asistanlarından Dilara DŐNGER KARA ile Ceyda SARIAL SEVİN'e teőekkűr ederim.

alıőmalarım boyunca teknik yardımları iin deđerli arkadaőlarım Gűlően ELEBİ ve Ahmet ŐEKER'e; tezimde yer alan grafiklerin izimindeki destekleri iin Lűtfi KŐSE'ye; alıőmam sűresince bana destek olan deđerli aileme teőekkűrlerimi sunarım.

# İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET .....	i
ABSTRACT .....	iii
TEŞEKKÜR .....	v
İÇİNDEKİLER .....	vi
ŞEKİLLER DİZİNİ .....	x
ÇİZELGELER DİZİNİ .....	xi
SİMGELER VE KISALTMALAR .....	xiii
SÖZLÜK DİZİNİ .....	xv
1. GİRİŞ .....	1
1.1. Tezin Kapsamı .....	4
1.2. Tezin Katkıları .....	4
1.3. Tezin Organizasyonu .....	6
1.4. Önceki Çalışmalar .....	7
1.4.1. İnsan Hareket Tanıma .....	7
1.4.2. RGB-D Veri Setleri .....	10
1.4.3. Ev Rehabilitasyonu İçin Yardımcı Sistemler .....	10
1.4.4. Rehabilitasyon Motivasyon Sistemleri .....	11
1.4.5. Egzersiz Oyunlar .....	12
2. OMUZ FİZYOTERAPİSİ .....	15
2.1. Fizyoterapi ve Rehabilitasyon .....	15
2.2. Fizyoterapist .....	16
2.3. Omuz Yapısı .....	17
2.4. Omuz Rahatsızlıkları .....	18
2.4.1. Donuk Omuz (Adeziv Kapsülit) .....	18
2.4.2. İmpingement Sendromu .....	20

2.4.3. Bisipital Tendinit	20
2.4.4. Kalsifiye Tendinit	21
2.5. Omuz Fizyoterapi Hareketleri	21
2.5.1. Wand Egzersizi Omuz Fleksiyonu:	22
2.5.2. Wand Egzersizi Omuz Abduksiyonu:	22
2.5.3. Omuz Posterior Kapsül Germe:	22
2.5.4. 90° Omuz Fleksiyonu:	22
2.5.5. 90° Omuz Abduksiyonu:	23
2.5.6. Eksternal Rotasyon Yönünde Germe:	23
2.5.7. Dirsekler Fleksiyonda Skapular Retraksiyon:	23
3. VERİ SETLERİ	24
3.1. Hacettepe Omuz Veri Seti - 1	25
3.1.1. Hacettepe Omuz Veri Seti - 2	27
3.1.2. Hacettepe Omuz Veri Seti - 3	28
3.1.3. Hacettepe Omuz Veri Seti - 4	29
3.1.4. Hacettepe Omuz Veri Seti - 5	30
3.2. RGB-D Fizyoterapi Egzersiz Verisinin Ön Analiz Edilmesi	32
3.2.1. Fizyoterapi Hareketlerinin Kaydedilmesi	33
3.2.2. Kinect Tanınan Kemikler	35
3.2.3. Fizyoterapi Hareketlerinin Kaydedilme Konfigürasyonu	35
4. SINIFLANDIRMA	36
4.1. Veri Madenciliği	36
4.2. Kümeleme	38
4.2.1. K-means Kümeleme Yöntemi	38
4.2.2. K-medoid Kümeleme Yöntemi	40
4.2.3. Uzaklık Ölçütleri	41
4.2.3.1. Minkowski Uzaklığı	41

4.2.3.2. Öklid Uzaklığı	41
4.2.3.3. Manhattan Uzaklığı	42
4.2.3.4. Chebyshev Uzaklığı	42
4.3. Kestirimsel Modelleme	42
4.4. Sınıflandırma Problemi	43
4.4.1. Gözetimli Sınıflandırma Yöntemleri	43
4.4.1.1. Karar Ağaçları	44
4.4.1.1.1CHAID Algoritması	47
4.4.1.1.2CART Algoritması	49
4.4.1.2. Destek Vektör Makineleri	49
4.4.1.3. Doğrusal Destek Vektör Makineleri	50
4.4.1.4. Doğrusal Olmayan Destek Vektör Makineleri	54
4.4.1.5. K-En Yakın Komşuluğu	56
4.4.1.6. Topluluk Öğrenmesi Metotları	58
4.4.2.	59
4.4.2.1. Tek Girişli Nöron	59
4.4.2.2. Çoklu Giriş Nöronu	61
4.4.2.3. Tek Katmanlı Ağ Mimarisi	62
4.4.2.4. Çok Katmanlı Ağ Mimarisi	62
5. OMUZ FİZYOTERAPİ HAREKETLERİNİN SINIFLANDIRILMASI	64
5.1. Fizyoterapi Egzersiz Hareketlerinin Özetlenmesi	64
5.1.1. En Düşük Kare Sayısı'nda Kesme	65
5.1.2. Rastsal Yaklaşım	65
5.1.3. Hareket Özetleme Tekniği	65
5.2. Fizyoterapi Egzersiz Hareketlerinin Sınıflandırılması	67
5.2.1. Destek Vektör Makineleri	68
5.2.2. Kalibre Edilmiş Destek Vektör Makineleri	69

5.2.3. Karar Ağaçları .....	70
5.3. K-En Yakın Komşuluğu .....	71
5.3.1. Yapay Sinir Ağları (MLP) .....	73
5.3.2. Topluluk Öğrenmesi .....	74
6. SANAL FİZİYOTERAPİ EGZERSİZ SİSTEMİ TASARIMI .....	76
6.1. İstemci Mimarisi .....	77
6.1.1. Egzersiz Yeniden Görselleme .....	77
6.1.2. Ayarlar Menüsü .....	77
6.1.3. Demo Modu .....	80
6.1.4. ViTES Uygulaması Akışı .....	80
6.2. Sunucu Mimarisi .....	81
6.2.1. Temsili Durum Transfer Servis (REST) Yaklaşımı .....	82
6.2.2. Veri Madenciliği Katmanı .....	82
6.3. Kinect Mimarisi .....	83
6.4. Unity Kinect Entegrasyonu .....	85
7. SONUÇLAR .....	86
7.1. Veri Madenciliği Sonuçları .....	86
7.2. ViTES Sanal Egzersiz Sistemi'nin Etkinliğinin Araştırılması .....	87
7.2.1. Likert Araştırması .....	89
7.2.2. Hareketi En İyi Temsil Eden Kare (Frame) Sayısı Etkisi .....	92
7.3. Mimarinin Oluşturulması Konusunda Sonuçlar .....	93
7.3.1. 1. Mimari Seçimi .....	93
7.3.2. 2. Mimari Seçimi .....	94
7.3.3. 3. Mimari Seçimi .....	94
7.4. Sonuç .....	94
KAYNAKLAR .....	97
ÖZGEÇMİŞ .....	104

## ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1. Veri Seti .....	25
Şekil 3.2. Kinect Tanımlanan Kemikler .....	34
Şekil 3.3. Kinect Görüntüleme ve Kaydetme Uygulaması .....	34
Şekil 3.4. Veri Seti Toplama Kinect Konum Konfigürasyonu .....	34
Şekil 4.1. Bilgi keşfi süreci ve veri madenciliği .....	37
Şekil 4.2. Bilgi keşfi süreci ve veri madenciliği .....	38
Şekil 4.3. Karar Ağaçları .....	45
Şekil 4.4. Doğrusal Dağılabilen Veri Seti İçin Muhtemel Karar Düzlemleri Dağılımı	50
Şekil 4.5. Karar Düzlemleri Marjin Gösterimi .....	51
Şekil 4.6. Karar Düzlemleri Marjin Gösterimi .....	52
Şekil 4.7. Doğrusal olmayan örnek uzayının doğrusal hale getirilmesi .....	55
Şekil 4.8. K-En Yakın Komşu - Bilinmeyen bir değişken grubunun ataması .....	57
Şekil 4.9. Topluluk Öğrenmesi Metotların hata oranının Temel Sınıflandırıcı hata oranına göre değişimi .....	59
Şekil 4.10. Tek Girişli Nöron .....	60
Şekil 4.11. Çok Girişli Nöron .....	61
Şekil 4.12. Tek Katmanlı Ağ .....	62
Şekil 4.13. Çok Katmanlı Ağ .....	63
Şekil 5.1. Hareket Özetleme Yöntemi .....	67
Şekil 6.1. Ana Ayarlar Menüsü .....	78
Şekil 6.2. Sanal Egzersiz Sistemi ViTES - Unity3D Oyunu Ekran Görüntüsü .....	78
Şekil 6.3. Egzersiz Oluşturma Ayarları Menüsü .....	79
Şekil 6.4. Sanal Egzersiz Sistemi ViTES Mimarisi .....	79
Şekil 6.5. Sonuç Ekranı .....	79
Şekil 6.6. Kinect İnsan Tanıma Algoritması .....	84

## ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 3.1. Hacettepe Omuz Veri Seti - 1 Egzersiz Sayıları ve Kodları .....	26
Çizelge 3.2. Hacettepe Omuz Veri Seti - 2 Egzersiz Sayıları ve Kodları .....	28
Çizelge 3.3. Hacettepe Omuz Veri Seti - 3 Egzersiz Sayıları ve Kodları .....	29
Çizelge 3.4. Hacettepe Omuz Veri Seti - 4 Egzersiz Sayıları ve Kodları .....	30
Çizelge 3.5. Hacettepe Omuz Veri Seti - 5 Egzersiz Sayıları ve Kodları .....	31
Çizelge 4.1. Transfer Fonksiyon Listesi ve Gösterimi .....	61
Çizelge 5.1. Destek Vektör Makineleri - Hassasiyet - Duyarlılık - Destek Sonuçları, K=10 .....	68
Çizelge 5.2. Destek Vektör Makineleri Sınıflandırıcı Hata Matrisi, K=10.....	69
Çizelge 5.3. Kalibre Edilmiş SVM Sınıflandırıcı - Hassasiyet - Duyarlılık - Destek Sonuçları, K=10 .....	70
Çizelge 5.4. Kalibre Edilmiş Destek Vektör Makineleri Sınıflandırıcı Hata Matrisi, K=10 .....	70
Çizelge 5.5. Karar Ağaçları Sınıflandırıcısı Hassasiyet - Duyarlılık - Destek Sonuçları, K=10 .....	71
Çizelge 5.6. Karar Ağaçları Sınıflandırıcı Hata Matrisi, K=10 .....	71
Çizelge 5.7. KNN - Hassasiyet - Duyarlılık - Destek Sonuçları, K=10 .....	72
Çizelge 5.8. KNN Sınıflandırıcı Hata Matrisi, K=10 .....	73
Çizelge 5.9. MLP Sınıflandırıcısı - Hassiyet Duyarlılık - Destek Sonuçları, K=10 ..	73
Çizelge 5.10. MLP Sınıflandırıcı Hata Matrisi, K=10.....	74
Çizelge 5.11. Topluluk Öğrenmesi Sınıflandırıcı - Duyarlılık - Destek Sonuçları, K=10 .....	75
Çizelge 5.12. Topluluk Öğrenmesi Sınıflandırıcı Hata Matrisi (Confusion Matrix), K=10 .....	75
Çizelge 7.1. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 1. Grup (En iyi Kare Sayısı: 10, SVM).....	87



Çizelge 7.2. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 2. Grup (En iyi Kare Sayısı: 10, SVM) .....	88
Çizelge 7.3. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri (En iyi Kare Sayısı: 10, SVM) .....	88
Çizelge 7.4. Likert ölçeğinin Hacettepe Fizyoterapi ve Rehabilitasyon Bölümü'ndeki kullanıcılara uygulanmış ve Cevap Yüzdeleri .....	90
Çizelge 7.5. Likert sorularına Deney Grubu 1 tarafından verilen cevaplar ve cevap veren kullanıcıların özellikleri .....	91
Çizelge 7.6. Likert sorularına Deney Grubu 2 tarafından verilen cevaplar ve cevap veren kullanıcıların özellikleri .....	91
Çizelge 7.7. Likert sorularına kullanıcılar tarafından verilen cevaplar ve kullanıcıların özellikleri .....	91
Çizelge 7.8. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 1. Grup (En iyi Kare Sayısı: 20, SVM) .....	92
Çizelge 7.9. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 2. Grup (En iyi Kare Sayısı: 20, SVM) .....	92
Çizelge 7.10. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri (En iyi Kare Sayısı: 20, SVM) .....	93

## SİMGELER VE KISALTMALAR

### Simgeler

-

### Kısaltmalar

ViTES	Virtual Training Environment for Shoulder Exercises
FT	Fizyoterapist
HMR	Human Motion Recognition
HCI	Human Computer Interaction
XML	Extensible Markup Language
JSON	JavaScript Object Notation
HTML	Hyper Text Markup Language, Hiper Metin İşaret Dili
HTTP	Hypertext Transfer Protocol
PCM	Pulse Code Modulation
RGB	Red, Green, Blue Color Definition System
KYM	Kırmızı, Yeşil, Mavi Renk Tanımlama Sistemi
KNN	K-En Yakın Komşu
MoCaP	Motion Capture
PRC	Precision Recall Curve
DTW	Dynamic Time Warping
PCA	Principal Component Analysis
KA	Karar Ağaçları
DVM	Destek Vektör Makineleri
FPS	Kare/Saniye
CMOS	Complementary Metal Oxide Semiconductor
NSAIDS	Non-steroidal anti-inflamatuar steroids
SOAİ	Steroid Olmayan Anti-İnflamatuvar İlaçlar
TENS	Transcutaneous Electrical Nerve Stimulation

CHAID	Chi-Squared Automatic Interaction Detector
CART	Classification and Regression Treea
MARS	Multivariate Adaptive Regression Splines
QUEST	Quick, Unbiased, Efficient Statistical Tree
SLIQ	Supervised Learning in Quest
SPRINT	Scalable Paralleizable Induction of Decision Trees
ESWT	Extracorporeal Shock Wave Therapy
RGF	Radial Basis Function
CLI	Command Line Interface
JSON	JavaScript Object Notation
MLP	Multilayer Perceptrons
ANN	Artificial Neural Network



## SÖZLÜK DİZİNİ

Boyutsallık Laneti	: The Curse of Dimensionality
Kare Hızı	: Frame Rate
Destek Vektör Makineleri	: Support Vector Machine
Kestirimsel Modelleme	: Predictive Modelling
Eşleştirme Kuralları Madenciliği	: Association Rule Minings
Sınıflandırma ve Regresyon Ağaçları	: Classification and Regression Tree
Doğrusal	: Linear
Doğrusal Olmayan	: Nonlinear
Eşik Değeri	: Threshold
Hassasiyet	: Recall
Keskinlik	: Precision
Karar Ağacı	: Decision Tree
Karışıklık Matrisi	: Confusion Matrix
K-En Yakın Komşuluğu	: K-Nearest Neighbours
Öznitelik Uzayı	: Feature Space
Öznitelik	: Feature
Eşik Değeri	: Threshold
Kusur	: Defect
Veri Seti	: Dataset
Rastsal Orman	: Random Forest
Topluluk Öğrenmesi	: Ensemble Methods
Doğrusal	: Spatial
İlgi Alanı	: Point of Interest
Noktasal Tanımlayıcılar	: Pointwise Descriptor
Öznitelik Çantası	: Bag of Features
Şablon Tabanlı	: Template Based
Hareket Yakalama Teknolojileri	: Motion Capture Technologies
Şablon Eşleme	: Template-matching
Oyunlaştırma	: Exergaming
Duruş, postür	: posture
Manhattan Uzaklığı	: City-Blok Distance

Otomatik Ki-Kare Etkileşim Belirleme	: Chi-Squared Automatic Interaction Detect
Sınıflandırma ve Regresyon Ağaçları	: Classification and Regression Tree
Çok Değişkenli Uyumsuz Regresyon Uzanımları	: Multivariate Adaptive Regression Splines
Hızlı, Yansız, Etkin İstatistiksel Ağaç	: Quick, Unbiased, Efficient Statistical Tree
Rastgele Altuzaylar	: Random Subsample
Omuz Egzersizleri İçin Sanal Egzersiz Sistemi	: Virtual Training Environment For Shoulder Rehab.
İnsan Bilgisayar Etkileşimi	: Human Computer Interaction
Nesne İlişki Haritalama	: Object Relation Mapping
Yapay Sinir Ağları	: Artificial Neural Network
Ceza işlevsisi Değeri	: The Penalty Parameter

# 1. GİRİŞ

Omuz ağrıları ve rahatsızlıkları çok yaygın olarak görülen bir problemdir ve dünya nüfusunun %34'üne yakınında rastlanır [1]. Omuz rahatsızlıkları, hastalar tarafından birincil basamak sağlık hizmetlerine yapılan başvurularda üçüncü sırayı almaktadır [2]. Bu nedenle donuk omuz hastalığı önemli bir rahatsız olarak sayılır [2]. Tedavi olarak; fizyoterapi, SOAİ, kortikosteroid enjeksiyonu ve ameliyat sayılabilir [3] [4].

Fizyoterapi doğru şekilde ele alınmadığında ve gözetimli şekilde yapılmadığında hastanın hayat kalitesini azaltıcı sonuçlara neden olabilir ve tedavi sürecinde hastanın ağrılarında artmaya neden olabilir. Hareketlerin yanlış veya denetimsiz yapılmasından kaynaklı asıl hedef rahatsızlığın çözümü bir yana; tedavi yanlış uygulandığı iyileşme görülemeyeceği gibi ilgili uzuv ya da farklı bağlantılı uzuvların sakatlanmasına yol açabilir. Bu ciddi süreçte klasik fiziksel terapi süresi boyunca, hastalar iki şekilde fizyoterapi alabilirler. Bu terapiler:

- Fizyoterapist ile doğrudan etkileşim,
- Fizyoterapist tarafından hazırlanan doküman (egzersizleri açıklayan broşür) eşliğinde evde terapi (fizyoterapist gözetimi olmadan).

Bir fizyoterapist eşliğinde rehabilitasyon egzersizlerini doğru ve gözetimli bir şekilde yerine getiren hasta gruplarının; fizyoterapist tarafından hazırlanmış olan hareketin nasıl yapılacağına dair bilgileri içeren broşürler aracılığı ile tedavi sürecini gerçekleştiren hastalara göre daha az ağrı yaşamaktadır [5].

Fizyoterapist eşliğinde yapılan egzersizlerin avantajlarının yanı sıra eksileri de bulunmaktadır. Genellikle, bir fizyoterapi seansında, fizyoterapist birden fazla hasta ile ilgilenmek zorunda kalmaktadır. Bu durumda fizyoterapist, hastanın iyileşme süresi durumu veya performansına göre bir hastaya diğerinden daha çok ilgi ve zaman ayırabilmektedir. Bunun sonunu olarak, hastalar egzersiz hareketlerini yanlış yapabilir, planlanan sayıda set yapamayabilirler. Bu durumda ise, hastalığın iyileşme uzamakta ve hasta ağrılı bir sürece maruz kalmaktadır. Dolayısıyla ağrıların artmasıyla birlikte hastaların

fizyoterapi egzersizlerine devam etmek için olan bağılılıkları azaltmaktadır. Fizyoterapistler, fizyoterapi seanslarında hastaların yaptıkları hareketleri ve gelişim süreçlerini unutabilmektedir. Hastalığın gelişimini değerlendirmek istenildiğinde, fizyoterapistin hafızası veya aldığı notlar kaynak olabilmektedir; ancak bu durum fizyoterapistin hasta sayısı arttığında yönetimi çok zor bir süreç haline gelir ve fizyoterapi tedavisinin etkinliğini ve kalitesini azaltıcı etki yaratmaktadır. En önemlisi de fizyoterapistler hastalarının egzersiz seansını tam olarak analiz edememektedirler; değerlendirmelerini ancak gözlem yoluyla yapabilmekte, nicelik olarak geçerli olan verilerle sonuç elde edememektedir.

Sağlık, oyun ve gözetleme sistemlerinde insan hareketlerinin doğru yorumlanması ve sınıflandırılması son yıllarda araştırma alanlarında büyük ilgi çekmektedir [6].

Sanal gerçeklik, bilgisayar yazılımları ve donanımları kullanılarak, sanal ortama gerçek dünya ortamının yaratılmasını içeren bir simülasyon türüdür. Son zamanlarda bilgisayar sistemlerinin rehabilitasyon alanında kullanımı klinikte kabul görmektedir. 2000'li yılların başında başta ABD olmak üzere, sanal gerçeklik ortamı yaratarak kişilerin rehabilitasyonunda klasik rehabilitasyondan daha hızlı ve etkin sonuçlar alınabileceğini gösterilmiştir. Ortam hakkında bilgi sağlanması gerçek dünyada duyu (görme, işitme, dokunma, koku) yoluyla mümkün olurken, sanal dünyada birtakım cihazların kullanımını gerektirmektedir. Görsel bilgi sağlamak amacıyla bilgisayar ekranı, LCD ekran, cihazlar kullanılabilir. Sanal gerçeklik alanındaki egzersiz türlerini dört grupta sınıflandırmak mümkündür.

Birincisi spesifik hasta popülasyonuna göre sınıflama metodudur. Bu sınıflamada egzersiz uygulamaları müskuloskeletal hastalıklar, inme sonrası ve kognitif ve psikolojik hastalıklar sonrası yapılan uygulamalar olarak sınıflanabilir.

Diğer bir sınıflama metodunda ise, kullanılan terapötik yaklaşım dikkate alınır. Terapötik yaklaşımlar olarak, örnekler ile eğitim yaklaşımı, video oyunları ile eğitim yaklaşımı veya psikolojik hastalıklarda kullanılan "maruz bırakma" yolu ile egzersiz yaklaşımı sayılabilir. Örnekler ile eğitim metodu, inme rehabilitasyonunda sıklıkla kullanılmaktadır. Bu yaklaşımda sanal ortamda oluşturulmuş bir öğretmen obje, doğru hareketi hastalara öğretmek amacıyla kullanılır. Örneğin hastanın kol hareketlerini algılayan bir sistem, kol



hareketlerini belli bir objenin hareketi olarak bilgisayar ekranına yansıtır ve hastadan, kol hareketlerini kontrol ederek, öğretmen objenin gösterdiği şekilde bir hareket oluşturması istenir.

Video oyunlarının kullanıldığı yaklaşımda ise, hasta belli bir eklem veya vücut hareketiyle, oyundaki cisimleri kontrol etmeye çalışır. Bu yöntemi uygulamak için, hastaların daha yüksek bir kognitif düzeye sahip olmaları gerekir.

Son olarak, sanal gerçeklik egzersizleri, terapistin yakınlığı veya uzaklığına göre sınıflanabilir. Lokal tedavide terapist ile hasta birbirlerinin yakınındayken, Tele rehabilitasyon metodunda, hasta terapistten uzak bir yerde rehabilitasyon sürecine katılır.

Bu doğrultuda çözüm önerimiz; omuz fizyoterapi egzersizlerini hastaya öğretmek ve ev egzersizlerini doğru yapabilmesi için geri bildirim yetenekleri temel hedefindedir. Çalışma sınıflandırma yöntemlerinden,

- terapötik,
- telefizyoterapi

sınıflandırılmasında değerlendirilebilir.

Gelişen teknoloji ile birlikte, araştırmacılar, fizyoterapi seanslarını geliştirmeye yönelik sistemler geliştirdiler. Bu sistemlerde konum bazlı olarak iki sınıfa ayırabiliriz. Bunlar; evde kullanım odaklı veya fizyoterapi kliniklerinin etkinliğini arttırmaya yönelik olanlardır. Fizyoterapi sistemlerinin en önemli amaçları aşağıdaki gibidir:

- Hastayı egzeriz hareketini doğru yapmaya yönlendirme,
- Hastanın fizyoterapi seansına ve ev ödevlerine olan bağlılığını arttırma,
- Hastaya yaptığı fizyoterapi hareketinin doğruluğu hakkında geri bildirim verme,
- Fizyoterapist tarafından hastanın hangi hareketlerini doğru yapıp yapmadığı bilgisine erişerek kişiye özgü tedavi modeli geliştirebilme konusunda geri bildirim sağlamak,

- Fizyoterapistte hastanın fizyoterapi sürecini tarih bazlı inceleme olanağı sağlamaktır.

## 1.1 Tezin Kapsamı

Tez kapsamı aşağıdaki gibi özetlenebilir:

- Hacettepe Üniversitesi Fizyoterapi ve Rehabilitasyon Bölümü'nün desteğiyle omuz için kullanılan klasik egzersiz hareketleri belirlenerek RGB-D kamera ile veri setleri oluşturulması,
- Oluşturulan veri seti üzerinden veri madenciliği algoritmaları kullanılarak (kümeleme ve sınıflandırma algoritmalarıyla), egzersiz hareketlerinin özetlenmesi ve öğrenilmesi ve sonuçlarının paylaşılması,
- Sanal Gerçeklik Asistanı (ViTES) uygulamasının geliştirilmesi ve test edilmesi, etkinliğinin analiz edilmesi gibi adımlar gerçekleştirilmiştir ve sonuçları raporlanmıştır.

## 1.2 Tezin Katkıları

Çalışmanın fizyoterapi ve rehabilitasyon alanına (probleme özgü) sağladığı katkılar aşağıdaki gibidir:

- Klasik omuz egzersiz hareketlerinin sanal egzersiz sistemi ortamına aktarılması,
- Sanal egzersiz ortamında kullanıcıya klasik fizyoterapi egzersiz hareketlerinin eğitiminin verilmesi,
- Oyunlaştırma kullanılarak fizyoterapi seansına bağlılığın artırılması, sanal egzersiz sistemi ortamında hareketlerini tekrarlanması,
- Kullanıcının hareketleri doğru yapamaması durumunda, sanal egzersiz sisteminin kullanıcıyı uarması ve kullanıcıya bir geri bildirim mekanizması oluşturulması,

- Kullanıcının hareketleri yapma doğruluğu bilgileriyle, fizyoterapiste kişiye özgü bir tedavi programının oluşturulmasını destek olmak,
- Sanal egzersiz sisteminin ve oyunlaştırmanın etkisiyle klasik fizik tedavi sürecindeki sıkıcı ve acı verici aktivitelerin etkisini azaltmak ve egzersize bağlılığı arttırmak,
- Fizyoterapistin hastayı gözlemleyemediği seans dışı evrelerde de (ev ödevi) hastalığının gözlemleyebilmesi,
- Fizyoterapistin, hastanın ev ödevi yapma verilerine (terapiye ayırdığı süre ve tarih, egzersizliklerin ne doğrulukta yapıldığı, hangi egzersizlerin yapılamadığı) ulaşarak hastalığının tüm süreçlerine dair bilgi edinmesi ve hastalığının ilerleyişini gözlemlemesi ve uygulanan metodun diğer hastalar içinde uygulanabilirliğinin kontrol edilmesi.

Çalışmanın literatürel katkılarını (bilgisayar bilimi açısından) aşağıdaki gibi sıralayabiliriz:

- Omuz rehabilitasyon hareketlerinin tanınması ve bu hareketleri hastanın ne doğrulukta yaptığının tespit edilmesi için veri madenciliği algoritmalarının gereksinim duyduğu veri setlerine ihtiyacı bulunmaktadır. Omuz rehabilitasyonu için oluşturulmuş erişilebilir veri seti kısıtlılığı bulunmaktadır. Bu kapsamda, omuz fizyoterapisi için kullanılan 7 egzersiz hareketi, 15 fizyoterapist, 5 sağlıklı birey ve 10 fizyoterapi seanslarına katılan kişiler tarafından RGB-D kamera ile kayıt altına alınarak 5 adet veri seti (906 egzersiz hareketi içeren) oluşturulmuştur. Bu doğrultuda, hareket kaydı içinde bir yazılım geliştirilmiştir.
- Bir hareket için, RGB-D kamera tarafından elde edilen kare (frame) sayısının çokluğu nedeniyle, veri madenciliği algoritmalarında oluşturulan öznitelik sayısında artış olmaktadır. Bu da sınıflandırma performanslarında ciddi düşüşe neden olmaktadır. Bu sorunun önüne geçmek için, "Hareket Özetleme Metodu" Şekil 5.1 bölümünde ortaya konulmuştur ve bir hareketi en iyi temsil eden çerçeveler tespit edilip, öznitelik çıkartma sürecinde kullanılmıştır.

- Oluşturulan veri seti, veri madenciliği algoritmaları kullanılarak sınıflandırılmıştır. Eğitim ve test performansları paylaşılacaktır.
- Oluşturulmuş özetleme tekniği ve sınıflandırıcıların katkılarıyla, hastaların kullanması ve fizyoterapi sürecinde ortaya çıkan ev ödevlerindeki egzersizleri doğru yapma süreci denetim altına almak için "Sanal Egzersiz Sistemi" isimli bir oyun geliştirilmiştir. Bu oyun sayesinde, fizyoterapi süreci maliyetlerinin düşürülmesi, hastanın fizyoterapist olmadığı süreçte de yaptığı egzersizler hakkında geri bildirim almasının sağlanması hedeflenmiştir. Hastanın fizyoterapi sürecine bağlılığını arttırmak için oyunlaştırma kullanılmıştır.
- Fizyoterapist tarafından hastaya özgü verilen fizyoterapi ev ödevleri, hastanın Sanal Gerçeklik Asistanı oyununu kullanması sonucunda kayıt altına alınır. Fizyoterapist, seans süresi, hareketlerin doğru yapılma yüzdelerine tarihsel olarak ulaşabilir. Bu da hastalığın gelişim sürecini gözlemlemesine katkı sağlar.

### 1.3 Tezin Organizasyonu

Çalışmamızın organizasyonu bölümler bazında aşağıdaki gibidir:

Giriş 1 bölümünde; tezdeki problemin tanımı, tezin amacı ve tezin katkılarından bunun yanı sıra 1.4 alt bölümünde konu ile ilgili önceki çalışmalara yer verilmiştir.

Omuz Fizyoterapsi 2 bölümünde; omzun anatomisi, fizyoterapisi ve çalışmanın katkı sağlamayı hedeflediği omuz rahatsızlıkları açıklanmıştır. Buna ek olarak, çalışma kapsamında odaklanılan omuz fizyoterapi egzersiz hareketleri 2.5 alt bölümünde yapılaş şekilleri (eklem konum yapıları) açıklanmış ve örneklendirilmiştir.

Tezimiz kapsamında geliştirilen veri setlerine 3 bölümünde; veri seti oluşturma işlemi için yapılan işlemler ve bu veri setinin yapısı bu bölümde anlatılmıştır.

Sınıflandırma 4 bölümünde; çalışmada kullanılacak olan veri madenciliği teknikleri hakkında kuramsal bilgilere ve çalışma kapsamında neden seçildiği ve hedeflenen katkılar hakkında bilgiler verilmiştir.

Omuz Fizyoterapi Hareketlerinin Sınıflandırılması 5 bölümünde; çalışma kapsamında ortaya atılan "Hareket Özetleme Tekniği" hakkında bilgi verilip, test sonuçları paylaşılmıştır.

Sanal Egzersiz Sistemi (ViTES) Tasarımı 6 bölümünde; kullanıcılar üzerinde denenmiş olan sanal egzersiz sisteminin (ViTES) tasarım ayrıntıları açıklanmıştır.

Sonuçlar 7 bölümünde; ViTES uygulamasının etkinliğini incelemek üzere yapılan test sonuçlarına, fizyoterapi alanına katkıları konusunda sonuçlar ve kullanıcı yorumları (Likert çalışması) yer verilmiştir.

## **1.4 Önceki Çalışmalar**

### **1.4.1 İnsan Hareket Tanıma**

İnsan hareket tanıma, uzaysal olarak lokal, global ve parametrik sınıflandırmasında incelenebilir.

Lokal öznitelik yaklaşımlarında, her ilgi alanında noktasal tanımlayıcılar hesaplanır ve daha sonra hareket öznitelik çantası tekniği ile temsil edilir. Bu yaklaşım geçmiş yıllarda literatürde sıklıkla kullanılmıştır. [24], [25], [26], [27], [28]. Konum verileri kullanılarak oluşturulmuş lokal öznitelik çantası (bag of 3D points) yaklaşımı, Li et al. [36] tarafından geliştirilmiştir. Lokal öznitelik yaklaşımlarının dezavantajlı olarak sayılabilecek noktası uzaysal bilgisini ilgi noktaları arasında kaybetmesidir.

Global öznitelik yaklaşımlarında, global öznitelik olarak silüetler kullanılır [29], [30], [31] ve şablon tabanlı yaklaşımlar [32], [33] kullanılır ve bunlarda uzaysal bilgi korunur. Global öznitelik yaklaşımlarının dezavantajı insan iskelet ve eklem bilgilerini tanımlamadaki eksikleridir.

Sonuncu olarak, parametrik yaklaşımlar, insan iskelet ve eklemlerin konum bilgisini kullanarak insan vücudunun bir modelini üretmeye çalışmaktadır. İskelet verisini elde etmenin bir yolu işaretçi tabanlı hareket yakalama (MoCAP) teknolojileridir. Bu sistemlerde, insan vücudunda tanılanmak istenen noktalara işaretleyiciler takılır ve kamera sistemi bu işaretleyicilerin konum, hız ve ivme verilerine göre, insan vücudunu mo-

dellenmeye çalışır; Bu modellemeyi açılar üzerinden yapan iki çalışma bulunurken, [34], [35]; iskelet verileri üzerinden ise [37], [38] ancak bu sistem işaretleyicileri ve kamera(lara) çok bağılıdır. Maliyeti yüksek sistemlerdir ve ev ya da kişisel kullanıma şu anki haliyle uygun değildir.

Parametrik yaklaşımlarda, insan hareket tanıma, Kinect gibi düşük maliyetli derinlik kameraları ve hareket izleme teknolojisindeki ilerlemeler, gerçek zamanlı HCI vizyon tabanlı etkinlik tanıma için mevcut ve yeni tekniklerin geliştirilmesine yönelik yüksek bir talep yaratmıştır. Shotton ve çalışma arkadaşları [46] işaretleyicileri ihtiyaç duymadan 2D haritalardan Kinect kamera kullanarak, insan eklemleri gerçek zamanlı olarak elde etmeyi başardı. Mocap sistemlere göre, Kinect'ten kemik-iskelet verisini elde etmek daha kolaydır ve Mocap sistemlere göre düşük maliyeti nedeniyle tercih sebebidir; ancak çok hassas ölçümler için hala Kinect'te iyileştirmelere gerek duyulmaktadır. Kinect konum verilerini sunmada yeterli görülmeyle birlikte, ivme hesabının öznitelik olarak kullanımında sorunlara neden olmaktadır.

Uzaysal gösterimde (spatial), bir diğer sorunda insan hareketleri dizelerinde statik tabanlı hareketleri (ayağa kalkma, oturma, uzanma, düşme vb.) tanımak için klasik sınıflandırıcılar [57] veya şablon eşleme kullanılırken, dinamik hareketleri (koşma, zıplama gibi ardışık hareketler) sınıflandırmak için genellikle Hidden Markov Model [40] ya da hareket tabanlı modeller kullanılır. Bu şekilde birçok tür içeren dinamik hareketleri tanılamak kompleks ve zaman alıcıdır. Ayrıca bu modeller genellikle, yeni bir hareket için modeli genişletmeye uygun değildir [14].

Rayes ve çalışma arkadaşları [41], hareket serilerinin benzerliğini bulmaya çalışan DTW tekniğini kullanarak hareketlerdeki zaman senkron problemlerini (bir kullanıcının harekete bir diğerinden erken başlaması, bir kullanıcının ilgili egzersizi diğer kullanıcılara göre daha uzun sürede yapması gibi) çözmeye çalışmışlardır. Bu çalışmada Kinect kameranın önündeki kişinin duruş açısındaki farklılıklara toleransı arttırmışlar, ayrıca kişinin vücut değişikliklerindeki (boy, kilo vb.) farklılıklarının etkisini azaltmışlardır.

Raptis ve çalışma arkadaşları [39], bir çok farklı dans hareketini sınıflandırmak için Kinect kamera kullanarak PCA tekniği ile insan gövdesini açısal gösterimle açıklamaya

çalıştı. Sonuç olarak, yüksek tanıma oranına rağmen yöntemleri sadece dans hareketleriyle kısıtlıydı. Bilinmeyen bir müzik örüntüsünü belirleme de kısıtlıydı.

Rehabilitasyon ve oyunlaştırmayı birleştirerek, hastaların sıkıcı ve can yakıcı fizyoterapi süreçlerine olan motivasyonunu artırır. Bu alanda, Deboeverie ve çalışma arkadaşları [42], egzersiz oyunlaştırma kullanarak, çocukların fitness ya da rehabilitasyonunu sağlamak amacıyla bir çalışma yaptılar. Bu çalışmada Kinect, Rastsal Orman ve Destek Vektör Makineleri veri madenciliği tekniklerini kullanılarak gerçek zamanlı bir fizyoterapi asistanı geliştirmeyi amaçlamışlardır.

Hareket tanınması alanında, vücut takibi, postür (duruş) analizi ve eylem tanıma için Kinect iskelet çıktısını kullanmaya çalışan sınırlı sayıda çalışma vardır. Clark ve çalışma arkadaşları postür (duruş) kontrolü için Kinect vücut takip algoritmalarını gözden geçirdi [43]. Çalışma, Kinect'i eklem doğruluğu için VICON işaretçi (marker) tabanlı bir izleme sistemi ile karşılaştırdı. Çalışma Kinect'in postür analizinde yüksek derecedeki eklem doğruluğu nedeniyle potansiyel kullanımını sonlandırdılar. Bhattacharya ve çalışma arkadaşları, uçak marşlamasında kullanılan hareketleri tespit etmek ve sınıflandırmak için Destek Vektör Makineleri ve Karar Ağaçları'nı analiz ettiler [44]. Araştırmacılar, DVM'nin Karar Ağaçları'ndan daha üstün olduğunu bulmuşlardır, ancak yazarlar Karar Ağaçları'nın katılımcı anatomik farklılıklara duyarlı olduğunu, Destek Vektör Makinelerinin de katılımcının bağımsız olduğunu ve vücut duruşundaki farklılıklardan etkilenmediğini belirtmiştir.

Patsaduetal ve çalışma arkadaşları [45], popüler makine öğrenmesi algoritmalarının, insan düşümleri tahmin etmedeki performanslarını değerlendirmek için bir çalışma sergilediler. Üçüncüsü, diğer aktivitelerin hepsinin üzerinde, Destek Vektör Makineleri'nin üç aktiviteyi tahmin etmede ikinci olduğunu, yani küçük bir antrenman ve test veri seti üzerinde oturarak, yatarken ve ayakta durduğunu değerlendirdi. Bununla birlikte, bu önceki çalışmanın daha yakından incelenmesi, sonuçları etkilemiş olabilecek bazı önemli yanlışlıkları ortaya çıkarmaktadır. Birincisi, bu çalışma makine öğrenmesi algoritmalarının performansını birbirinden belirgin bir şekilde farklı olan sınırlı bir dizi aktivitede karşılaştırmıştır. İkincisi, veri kümesinin sınırlı boyutu ölçeklendiğinde anatomik farklılıkları etkilemez. Son olarak, Kinect, pozlama pozisyonlarını yakalamak için tasarlanmamıştır,

bu da konuya ve aktiviteye baęlı olarak eklemlerin tahmin edilemez ıkarımına yol aar.

### **1.4.2 RGB-D Veri Setleri**

İnsan hareket tanıma alıřmaları ierisinde veri seti yayımlayan alıřmalar bu blmde incelenecektir.

Kim ve arkadaşları tarafından dřk btceli gzetleme kameraları iin geliřtirilen insan eklem-iskelet konumlarını bulma ve bu bilgilerden insan hareket yapmayı hedefleyen bir alıřma sundular. Bu alıřmada sınıflandırıcıyı eęitmek ve test etmek iin kullandıkları veri setini de yayımlamıřlar. [9] Bu veri seti RGB-D ierięe sahiptir.

[9], [12], [13], [14], [15], [16] ya da sadece iskelet konum verileri zerinde [17], [18], [19], [20], [21], [22], [23] kullanılarak geliřtirilir.

### **1.4.3 Ev Rehabilitasyonu İin Yardımcı Sistemler**

Hastalar, evde rehabilitasyon egzersizlerini yaparken fizyoterapistin rehberlięi ve geri bildirimini bulunmuyor. Bu yzden, arařtırmacılar tarafından ev rehabilitasyonu iin geliřtirilmiř fizyoterapi sistemleri literatrde ok yaygındır. Ayoade ve Baillie [47] tarafından 2014 yılında yapılan alıřmada diz hareketlerine odaklanan ev rehabilitasyonu iin bir sistem geliřtirdiler. Sistemde dize baęlanan bir kablosuz eylemsizlik sensr ile ilgili hareket ve hareket aısı tanınarak ilgili diz grselleřtirmesi bilgisayara aktarılır. Hasta hareketleri yaparken elinde bulunan bir uzaktan kontrol birimi ile sistemi kumanda etmektedir. Hastalar gerek zamanlı olarak yaptıkları hareket ile ilgili geri bildirim alabilmektedir. Bu geri bildirimler, ayrıık iki ekran zerine yerleřtirilmiř bir diz avatarıyla hastanın yaptığı hareket ve doęru hareket gsterimi yapılır. Dizin hareket aralıęını belirten renk gradyanını deęiřtiren grafik bir bar ile hastaların ilerleme ve yaptığı nceki hareketlerin arřiv bilgileri tutulur. Fizyoterapist, bu arřiv bilgilerine uzaktan eriřerek hastanın ilerleyiřini kontrol edebilir, arřiv bilgilerini gzlemleyebilir. Bu sistem, diz deęiřimi ameliyatı geiren hastaların akut fazında bulunan hastalar zerinde deęerlendirildi. Bu ařamada rehabilitasyon genellikle sadece oturmuř ve sırtst egzersizler iin yapılır ve iyileřme eklem aıklıęını yakalamak genel amatır. Tasarlanan sistem ev rehabilitasyonuna odaklandıęından fizyoterapist ile etkileřim konusuna ok az odaklanılmıřtır.



Rehabilitasyon sürecinden iyi sonuç alınması için gerekli olan, egzersiz programının fizyoterapist tarafından değiştirilip değiştirilemeyeceği belirtilmemiştir. Hastaların kendi yaptıkları hareket ile doğru yapılan hareketi ayırık ekranlarda görememeleri hastaların odaklanma sorunları yaşamalarına neden olmaktadır. Ek olarak, ev fizyoterapi için hastaların dizlerine bir sensör takmalarının gerekmesi ve yalnızca oturarak veya yatarak egzersiz yapılması sistemin eksileri olarak sayılabilir.

PT Vis [48], üzerinde diz açıklığını tespit etmeye yarayan sensörler içeren giyilebilir bir diz bandıdır. Cihazdaki grafiksel gösterim sayesinde, hasta diz egzersizleri yaparken görsel bir geri bildirim alabilmektedirler. Sistemin eksileri olarak ise, sistem sadece diz fleksiyon hareketinde ve bu hareketin açıklığı hakkında geri bildirim vermektedir. Hareketin doğru yapılıp yapılmadığı ya da hareketin hangi açıklıkta yapılması gerektiği, hastanın hangi hareket açıklığına ulaşması gerektiği gibi bilgiler eksiktir. Ayrıca hastanın yapmış olduğu önceki egzersizler de arşivlenmemektedir ve fizyoterapist ile bir arayüz bulunmamaktadır.

Etkileşimli Sanal Telerehabilitasyon (IVT) sistemi, benzer şekilde hastaların diz egzersizlerini ev rehabilitasyonu olarak yapmasını amaçlar. Bu sistemin etkileşimli uygulaması, gerçekleştirilecek egzersizi gösteren ve kullanıcının hareketi yapmasını bekleyen bir 3D avatardan oluşur; ancak bu sistemin hasta tarafından nasıl uygulanacağı açık değildir yani arayüzü kullanıcı dostu değildir. Buna rağmen IVT, fizyoterapist etkileşimi sunmaktadır. IVT, fizyoterapistler için sistem tarafından toplanan verileri uzaktan gözden geçirmelerine ve rehabilitasyon geliştikçe terapiyi değiştirmelerine izin veren bir arayüzü barındırır.

#### **1.4.4 Rehabilitasyon Motivasyon Sistemleri**

2005 yılında Kimel ve arkadaşları [50] tarafından bir dizlikten oluşan Thera-Network isimli bir çevrimiçi uygulama geliştirdiler. Geliştirilen dizlik diz açısını izler ve diz açısı değişimleri bir ışık aracılığıyla kullanıcıya bildirir. Çevrimiçi uygulama ise sistemi kullanan diğer hastalar ile motivasyon amacıyla hastalığın süreçleriyle ilgili paylaşımlar yapılabilmektedir. Bu yöntemle ağırlı bir süreç olan rehabilitasyon süreci eğlenceli hale getirilmeye çalışılmıştır; ancak dizliğin sağladığı diz açısı hakkında bilgi veren sistemi

bir otonom rehabilitasyon sistemi olarak tanımlamak mümkün değildir. Ayrıca fizyoterapistlerde hastanın gelişimini ya da daha doğrusu diz eklem açıklık bilgilerine ulaşabilmektedir; ancak sistemin fizyoterapistte hız, yapılış süresi ve kişiye özgü egzersiz programı hazırlama gibi yetenekleri sağlamadığı gözlemlenmiştir.

2014 yılında yayınlanan Sucar ve arkadaşları [51] üst vücudun çalıştırılmasına yönelik hastaların sistemle interaktif bir şekilde sanal gerçeklik temelli egzersiz yapmasını amaçlayan çalışmalarını duyurdular.

2013 yılında Anton ve arkadaşları [52] yılında geliştirdikleri KiRES sistemi ile uzaktan rehabilitasyon temelli bir ev rehabilitasyon sistemi sundular. Kinect kamera yardımıyla kullanıcının bir avatarını görselleştiren sistemde, kullanıcı yaptığı hareketi doğruya yakın olarak veya yanlış yaptığında bunu geri bildirim olarak sunulmaktadır. Sistemde ayrıca fizyoterapistlerin kişiye özgü program hazırlayabileceklerinden de bahsetmiş olmakla birlikte bununla ilgili detay verilmemektedir. Sistemin bir eksi yanı da insan hareket tanımada kullanılan tekniklere çalışmada değinilmemektedir.

#### **1.4.5 Egzersiz Oyunlar**

2017 yılında ilk defa Staiano ve arkadaşları [79] tarafından ilk defa "exergames" (İngilizce "exercise" ve "game" kelimelerinin birleşiminden türetilen kısaltma) ifadesi akademik literatürde kullanılmıştır. Egzersiz Oyunları oyuncuya eğlenceli ve heyecan verici bir ortamda fiziksel egzersiz yapmalarına olanak tanıyarak eğlenceyi oyun tarafındaki potansiyel sağlık uygulamalarıyla birleştirmeyi amaçlar. Buna göre Kinect tabanlı sistemler fizyoterapi egzersiz programları için düşük maliyetli ve keyifli bir ortam üretirken; aynı zamanda egzersiz oyunları, rehabilitasyondaki süreciyle ilgili nicel veri toplanmasında da önemli bir yeteneğine sahiptir. Dijital oyunların yüksek popülaritesi göz önüne alındığında, yaşlı erişkinlerin dengesini arttırmak için bir seçenek olarak egzersiz oyunları önerilmiştir. Yaşlı erişkinlerde, bu tedavi yöntemi, açık gözler ve kapalı gözler altında sessiz dururken düşme ve denge korkusunu arttırmak için kullanılmıştır. Önceden, Van Diest ve arkadaşları [82], 6 haftalık bir ev egzersiz programı tasarladılar ve görmeden duruş dengesi kontrolü konusunda çalışmalarını açıkladılar. Vriese ve arkadaşları tarafından [77], iki benzer kayak oyununun kütle merkezi hareketlerine yansıyan Stabilitate İş-

levsel Sınırları ile ilgili olarak katılımcıların ne kadar dengeye dayanıklı olduğu değerlendirilmiştir. Otuz genç ve yaşlı katılımcıdan oluşan gruplardan biri Wii Balance oyununu kullanıp, diğer grup ise Kinect tabanlı bir oyunu deneyimledir. Araştırma, denge uygulaması için kullanılan oyunlamlarda hareket zorluğunu değerlendirmenin önemini ortaya koymuştur. Chang ve arkadaşları [75], profesyonel iş yaşamındaki özgürlüğü arttırmak ve mesleki rehabilitasyonu toplamda yer edindirebilmek için staj eğitiminde Kinect tabanlı sistemleri duyurdular. Eğitime 2 hafta boyunca bilişsel engelli 4 katılımcı katıldı ve araştırmacılar nitel olarak Likert Ölçeği kullanarak müşterilerin geri bildirimlerini gözlemlediler. Araştırmacılar, önerilen yöntemin staj eğitiminde faydalı olduğunu gösterdiler ancak herhangi bir klinik ölçeği kullanmamaları çalışmanın eksi yönü olarak belirtilebilir. Pirovano ve arkadaşları [78], birincil ve ikincil rehabilitasyon programları içeren, egzersiz hareketleri kullanılarak modellenen mini oyunları içeren bir sistemi duyurdular. Sanal gerçeklik içeren bu oyunlarla, rehabilitasyon süreci ile oyunlaştırmayı kullandılar. Oyunlarda kullanılan zorluk, puan toplama kriterleri ve oyun süresi gibi oyun mekanikleriyle rehabilitasyon sürecini daha eğlenceli bir hale getirmeye çalıştılar. Cassola ve arkadaşları [73], Kinect zamanlı bir sanal gerçeklik ortamı oluşturarak çevrimiçi jimnastikçilerle yaşlı insanların birlikte çalışmasını sağlayan bir sistem sundular. Chang ve arkadaşları [74], motor beceri engeline sahip kullanıcılar için Kinect zamanlı bir sistem duyurdular. Bu sistem fizyoterapistler olmadan, eğitici bir modülle kullanıcılara eğitim vererek özelleştirilmiş egzersiz hareketleri kullanıcıların yapmasına izin veriyordu ancak sistemin olumsuz olarak görülebilecek tarafı fizyoterapide bu rahatsızlık konusunda kullanılan egzersiz hareketlerinin yerine özelleştirilmiş, basite indirgenmiş hareketleri kullanmaları sayılabilir. MirrARbilitation [76], herhangi bir işaretçi (marker) kullanmadan insan omuz hareketlerine odaklı bir sistem önerdiler. Omuz eklem açıklığının artırılmasını hedefleyen sistem bunu yaparken kullanıcıları motive eder ve fizyoterapistin egzersiz hareketlerinde açı ayarlaması yapmasına olanak sağlar. Kullanıcının yanlış hareket yapmasını önlemek için geri-bildirimler ve yönergeler de sunar. Tamnious ve arkadaşları [81], fonksiyonel rehabilitasyonun alt ekstremitte hareketi sırasında diz fleksiyon kinematiğini arttırmak için görsel ve kapasitif sensörler arasındaki oryantasyon tabanlı bir füzyon sistemini tasarlamak ve doğrulamaktır. Kinect ve IMU sensörleri, iskelet izleme fonksiyonundan gerçek zamanlı vücut hareketi görüntüsü elde etmek için füzyon yöntemi olarak genişletilmiş bir Kalman filtresi kullanılmıştır. Su ve arkadaşları

[80], DTW algoritması ve bulanık mantık teknikleriyle Kinect tabanlı ev rehabilitasyon sistemi duyurdular. Bu çalışma Kinect tarafından elde edilen derinlik verisinde kalça kemiğine odaklanarak bu derinlik verilerini yerel koordinatlara çevirerek kullanıcının egzersiz yapma kalitesini arttırmayı hedeflemiştir.

## 2. OMUZ FİZİYOTERAPİSİ

Çalışma kapsamında omuz rehabilitasyonun ev programında hastayı motive edici ve programını bağlılığı arttırıcı çözümler geliştirmek amaçlanmıştır. Bir diğer motivasyon ise hastanın omuz rahatsızlıklarını geri bildirim sağlayan bir uygulama ile (ViTES uygulaması) hastalarda sıklıkla görülen omuz rahatsızlarının iyileşme sürecine katkı sağlamaktır. Donuk Omuz, İmpingement Sendromu, Bisipital Tendinit ve Kalsifiye Tendinit sıklıkla görülen omuz rahatsızlıklarıdır. Bu rahatsızlıkların fizyoterapi ile cerrahi müdahaleye gerek kalmaksızın iyileştirilmesi, eklem hareket açıklıklarının arttırılması mümkündür. Bu süreçte önemli olan nokta hasta ev fizyoterapi programında tek başınadır ve geri bildirim alacağı bir mekanizma bulunmamaktadır. Çalışma kapsamında geliştirilen ViTES uygulaması ile hataların bu süreçte egzersizleri yanlış yapmasının önüne geçilerek de katkı sağlanmaktadır.

Bu bölümde fizyoterapi, fizyoterapist, omzun yapısı ve tezimiz kapsamında rehabilitasyonla iyileşmesi sürecine katkı sağlayabileceğimiz omuz hastalıklarına değinilecektir. Ayrıca bu omuz rahatsızlıkları için fizyoterapistler tarafından hazırlanan ve uygulanan egzersiz hareketleri incelenecek ve yapılaş şekilleri tariflenecektir.

### 2.1 Fizyoterapi ve Rehabilitasyon

Fizyoterapi, diğer bir adıyla fizik tedavi, yaralanma, hastalık, travma ya da yaşlılık gibi nedenlerle eksilme gösteren fonksiyonel hareketleri geri kazandırma amaçlı yapılan tanı koyma ve tedavi uygulama hedeflerini kapsayan tıp bilimidir [5]. Elektrik akımı, sıcak ya da soğuk uygulaması, egzersizler ya da çeşitli dalgalarla hastaların tedavi süreçlerini içerir. Bu tedaviler, genellikle fizyoterapi egzersizlerin kontrollü bir şekilde hastaya uygulanmasını içerir [7]. Tıp dilinde, "optimum nöromüsküloskeletal fonksiyonu edinme veya geri kazanmayı amaçlayan tedavi" olarak açıklanan fizyoterapinin uygulanması bazen uzun yıllar sürebilir. Fizyoterapide amaç, bireylerin yaşamsal faktörleri sağlıklı olarak yerine getirebilmesini sağlamaktır. Fizyoterapi, fiziksel uygulamanın dışında duygusallık ve sosyal ilişkiler gibi unsurları da kapsar. Tedavi uygulaması öncesinde bir takım laboratuvar bulguları ve muayeneye başvurulur. Elektrodiagnostik elektromiyografi (sinir iletim hızı) testi gerekli görülebilir. Fizik tedavi için özel bakım merkezleri, geriatri,

nörolojik, fitnes merkezleri ve spor eğitim tesisleri gibi alanlar bulunmaktadır. Fizyoterapinin verimliliği arttırmak için yarı-otonom veya otonom sistemlere ihtiyaç bulunmaktadır. Klasik fizyoterapi seanslarında, fizyoterapistin hastayı izlemesi hareketlerini düzeltmesi gerekebilir; ancak hastanın hareketi öğrenmesi uzun zaman alabilir ve bu da fizyoterapi seanslarına devamlılığını azaltabilir. Bu durumda otonom sistemlerde tekrar sayısı hastanın öğrenmesine bağlı olarak hastanın kendi tarafından ayarlanabileceğinden öğrenmeye katkısı fazladır ve psikolojik olarak devamlılığı olumsuz etkileyen bir süreç değildir; çünkü hasta kendi kendine tekrarlar yapmaktadır. Klasik fizyoterapinin verildiği tesise ulaşım zorlukları nedeniyle terapiye bağlılık azaltmaktadır. Bu nedenle otonom sistemlerde ev terapisi, ulaşım kolaylığı nedeniyle bağlılığı arttırmaktadır.

## **2.2 Fizyoterapist**

Fizyoterapistlik; hareket kaybına yol açan her türlü yaralanma, yaşlılık durumu ve hastalıkta, fonksiyon bozukluklarında, ağrılarda uzman bir hekimin teşhisi sonrası fizyoterapiye özgü değerlendirme yöntemlerini kullanarak birçoğu literatürde yer alan tedavi yaklaşımlarını planlayıp uygulamaya ve tedavi sürecinin gözlemlenmesine yönelik bilgi ve beceriyi kazanan, sağlık ve yaşam kalitesinin artırılmasında önemli görevler taşıyan bir meslektir [5].

Fizyoterapistler, terapi parametrelerini ayarlamak ve terapi seanslarını yönetmek ile sorumludur. Fizyoterapi seansları, sözlü komut/öğretim, egzersizi görsel olarak açıklama ve fiziksel yönlendirme (hareketin doğru yapıp yapılmadığına dair geri bildirim verme, hatalıysa düzeltme) gibi süreçleri içerir [8]. Fiziksel yönlendirmelerde yer alan geri bildirimler, hatalı hareketlerin düzeltilmesinde ve motor öğrenmede önemli bir etkidir ve tedavinin de başarımını artırır.

Klasik fizyoterapi seanslarında, hastanın zamanla birlikte ilerlemesini kayıt altına almak fizyoterapistin kişisel özverisine kalmaktadır. Fizyoterapistin klinik rehabilitasyon sürecinde aldığı notlar veya hasta ile ilgili aklında kalan bilgilerle (fizyoterapistin hafızası) süreç takip edilirken; otonom sistemler, terapi süresini, başarımını kaydedip, fizyoterapiste geri bildirim olarak verebilmektedir. Bu şekilde nicelik bakımından daha değerli bilgiler kayıt altına alınabilirken, geriye dönük olarak da istenildiğinde bu bilgilere erişim

sağlanabilmektedir.

### 2.3 Omuz Yapısı

Omuz eklemi, insanın bağımsız olarak hayatını devam ettirebilmesi için gerekli olan en önemli eklemlerden biridir. Gündelik ihtiyaçlarımız ve günlük işlevlerimiz için omuz eklemi normal hareket açıklığı çok önemlidir. Omuz bölgesi fonksiyonellik olarak birbirine bağımlı ve ritmik işlevsel bir eklem kompleksini içermektedir. Omuz eklem kompleksi vücudun hareket genişliği en fazla olan eklemdir. Omuz eklem kompleksinde anatomik yapıyı oluşturan gerçek eklemler (sternoklavikuler eklem, akromiyoklaviküler eklem glenohumeral eklem), iki tanesi işlevsel eklemler olmak üzere (skapulotorasik eklem, kora-koakromial ark) toplam beş eklem bulunur. Sternoklavikuler eklem, üst uzuvları gövdeye bağlayan eklemdir, bu nedenle kolların tüm hareketlerinde görev alır. Sınırlı olarak her yönde hareket edebilir. Akromiyoklaviküler eklem, bulunduğu pozisyonda gergin bağlar sayesinde durur. Bu nedenle hareket genişliği kısıtlıdır. Rotasyon ve kayma hareketleri vardır. Glenohumeral eklem, vücudun en geniş ve en çeşitli (abduksiyon, adduksiyon, fleksiyon, ekstansiyon, iç ve dış rotasyon) hareketleri yapabilen eklemdir. Eklem yüzleri birbiriyle çok uyumlu değildir. Bu yapılanma eklemi hareket genişliği arttırmaktadır.

Normal bir omuz eklemi, ortalama hareket açıları üst sınırları aşağıdaki gibidir [66]:

- Abduksiyon 160°,
- Adduksiyon 50°,
- Fleksiyon 180°,
- Ekstansiyon 60°
- İç rotasyon nötral 45° abduksiyonda 90°,
- Dış rotasyon nötralde ve abduksiyonda 90°

Temel ihtiyaçlarımızı karşılarken saç tarama hareketleri için en az 150° fleksiyon; traş olabilmek, diş fırçalamak, kaşık kullanabilmek için en az 50° fleksiyon; kıyafetlerimizi giyebilmek için nötralde ve abduksiyonda tama yakın iç rotasyona ihtiyaç vardır[66].

Omuz hareketleri bu eklemlerin koordine çalışmasıyla gerçekleşir. Omuz çevresi anatomisini oluşturan dört adet kemik vardır. Bunlar, sternum, klavikula, skapula ve humerus kemikleridir.

Omuz ekleminde 6 temel hareket yapılır. Dikey hareketler, yatay hareketler, dönme (rotasyon) hareketleri olarak sınıflandırılır. Dikey hareketlerde, aşağı sarkık olan kola nötral sıfır konumundan elevasyon yaptırılır. Yatay hareketler 90° abduksiyondaki kolu öne ve arkaya getirir. Fleksiyon ve ekstansiyon yatay ekseninde gerçekleşir. Abduksiyon ve adduksiyon önden arkaya doğru uzanan (sagittal) ekseninde gerçekleşir. 90°'nin üzerindeki hareketler sıklıkla elevasyon olarak isimlendirilir. Böylece omuz eklemi çok yönlü olarak hemen hemen tüm anatomik planlarda eklem 360° çevresine hakim olacak hareket genişliğine sahiptir. Bu hareket genişliğine dinamik stabilite sağlamak için sayısız kas etki eder. Omuz kas yapısı katmanlar şeklindedir. Bu kas yapısının yardımıyla, fleksiyon ve internal rotasyon, abduksiyon, ekstansiyon ve eksternal rotasyon gibi hareketler yapılır. Ek olarak, abduksiyon ve internal rotasyon yapılmasına bu kaslar yardımcı olur.

## **2.4 Omuz Rahatsızlıkları**

Fizyoterapi ve çalışma kapsamında geliştirilen ViTES uygulaması ile iyileşme sürecine katkı sağlanabileceğimiz omuz rahatsızlıkları bu bölümde açıklanacaktır. Bu omuz rahatsızlıkları; Donuk Omuz, İmpingement Sendromu, Bisipital Tendinit ve Kalsifiye Tendinit şeklinde sıralanabilir.

### **2.4.1 Donuk Omuz (Adeziv Kapsülit)**

Donuk Omuz, adeziv kapsülit; skapulo-humeral periartrit, periartiküler fibrozit, Duplay hastalığı gibi isimler ile de anılmaktadır [64]. Donuk Omuz sendromu ilk defa 1982 yılında Duplay tarafından ortaya atılmıştır. Neviasser, Donuk Omuz'un o güne kadar bilinen aksine "periartrit" olmadığını, "kapsülün humerus başına yapışık olarak kalınlaşması ve kısılması" olduğunu ortaya koymuş ve ilk kez "adeziv kapsülit" terimini kullanmıştır. Donuk Omuz, yavaş gelişen ve omuzda aktif ve pasif tüm hareketleri kısıtlayan, ağrı ile süregelen kendini kendini sınırlayan bir hastalıktır. Gleno-humeral eklem kapsülünün iltihaplanması ve geri dönüşümlü olarak katılığı ile seyreden, omuz eklemi-



nin bütün yönlerine olan aktif ve pasif hareketlerinde kısıtlılığa yol açan bir sendromdur [65].

Genel popülasyondaki yoğunluğu %3 olmakla beraber, sıklıkla 40 - 70 yaş arasındaki kadınlarda çoğunlukla görülmektedir. Temel rahatsızlık eklem kapsülündedir, eklem kapsülü katılaştır. Donuk omuz rahatsızlığını tetikleyen birçok etken bulunsa da, nedeni kesin olarak bilinmemektedir. İlk olarak, herhangi bir nedene bağlı olmaksızın gelişebildiği gibi, hastalığın ikincil formu, iç nedenler veya dışsal nedenler ile oluşur. İç nedenler olarak, omuz ekleminden kaynaklanan rotator manşet yırtıkları, omuz travmaları, biceps kasının tendonunun yırtıklarıdır. Dışsal nedenler ise, triod hastalıkları, kalp krizi ve felç gibi rahatsızlıklar, akciğer hastalıkları, insüline bağımlı olmayan şeker hastalarında %10 - %20 aralığında iken, insüline bağımlı şeker hastalarında donuk omuz yoğunluğu %36 oranında olduğu bildirilmektedir[65].

Tanısı; hikaye ve fizik muayene ile konulur. Hastalar tipik olarak artan ağrı ve ilerleyen hareket kısıtlılığı ile başvururlar. Gece ağrısı, hareket açıklığı sınırlarında ağrı ilk evrelerde görülür. İlerleyen evrelerde, aktif ve pasif hareketlerde ağrı ve kısıtlılık görülür. Birincil Donuk Omuz'da herhangi bir travma ve hastalık hikayesi yoktur. İkincil Donuk Omuz rahatsızlığına sahip hastalarda, diyabet, triod hastalıkları, kalp krizi ve karaciğer hastalıkları olma ihtimali vardır. Ağrı omuzun önüne, arkasına ve deltoid kasın üzerine yayılır. Genel olarak en az iki plandaki %25'den fazla hareket kaybı ve pasif eksternal rotasyonda %50'den fazla, aktif eksternal rotasyonda da %30'dan fazla kayıp olması donuk omuz rahatsızlığını düşündürür [66].

Hastalığın 3 aşaması bulunmaktadır. Ağrılı faz, ağrının şiddetli olduğu ve omuz hareketlerinde kısıtlılığın yavaş yavaş başladığı evredir [65]. Hastanın dinlenme evresinde ağrıları ve gece ağrıları artar. Kas spazmı gelişir ve bu fazın sonuna doğru hareket kısıtlılığı belirginleşir. Yaklaşık olarak 2 - 8 ay sürer [65]. İkinci fazı, adeziv faz olarak bilinir. Ağrı bu fazda azalır; fakat eklem hareket kısıtlılığı giderek artar. 4 - 6 ay sürer [65]. Son olarak ise, hastalığın çözülme/gevşeme fazında ağrı azalır, eklem hareketleri yavaş ve dereceli bir şekilde düzelir. Bütün hastalık dönemi 1 - 3 yıl sürebilir.

Donuk omuz hastalığının tedavisinin amacı, ağrının kontrolü ve eklem hareket açıklığı-

nın kazanılmasıdır [65]. Tedavisi, medikal tedavi, cerrahi tedavi ve fizyoterapi yaklaşımları olarak bilinir. Medikal tedavide, SOİD ilaçlar, kortikosteroid enjeksiyonu; cerrahi olarak ise ameliyat; fizyoterapi yaklaşımında ise, uygun fizyoterapi hareketleri ile egzersiz yapılması hedeflenir.

Ağrının giderilmesi için SOİD ilaçlar, ağrı kesiciler (analjezik), ısı modaliteleri (derin sıcaklık ile doku esnekliğinin artırılması) ve TENS (deri yüzeyine yakın sinirlerin elektriksel olarak uyarımını amaçlayan tedavi) kullanılabilir. Eklem kapsülünde hastalığa bağlı olarak gelişen yapısal değişikliğini gidermek için pasif germe fizyoterapi egzersizleri uygulanır. Lokal steroid uygulanması, anestezi altında fizyoterapi yaygın olarak kullanılır. Belirtilen yöntemlerde 12 - 16 haftalık bir sürede yanıt alınamazsa cerrahi müdahaleler seçilir.

#### **2.4.2 İmpingement Sendromu**

Omuz ağrısının en sık nedenidir. Rotator manşet kaslarının sıkışmasıyla meydana gelir. Hastalığın iç nedenleri, tendonun kendisinden kaynaklanan yıkımsal ve travmatik faktörler olarak değerlendirilir. Hastalığa sebep olan dış nedenler, tendonun etrafındaki yapılardan kaynaklanan hastalıklardır. Özellikle kolun baş üzerindeki hareketleri, yüzme, voleybol ve tenis gibi aktiviteler bu hastalığın meydana gelme riskini artırır. Fizik tedavi muayenesinde omuz çevresinde ağrı ve hassasiyet bulunur. Hastanın tanısı için uygulanan testin adı "ağrılı ark" testidir. Bu testte omuza abduksiyon yaptırılırken 70° - 120° arasında ağrı hissedilir. Tedavi olarak, bölgesel buz uygulaması, SOİD ilaçlar ve fizyoterapi uygulanır. Bunlardan da fayda görülmezse cerrahi işlem uygulanır.

#### **2.4.3 Bisipital Tendinit**

Biceps kasının tendonunun enfeksiyon kapmasıyla başlar. Kasın yırtılmasına kadar farklı etkiler içerir. Bu kasın tendonu omuz eklemine yerinde tutan en önemli yapıdır. Bu hastalık tek başına nadir görülür. Çoğunlukla diğer hastalıklara eşlik eder. Tanıda omzun ön kısmında hissedilen ağrı bu hastalığın belirtisidir. Tedavide ağrı ve eklem hareket kısıtlılığı ile mücadele edilir. İlaç olarak, SOİD kullanılır. Fizik tedavide fizyoterapi hareketleri ayrıca ultrason, lazer, yüzeysel ısıtıcılar kullanılır.

#### **2.4.4 Kalsifiye Tendinit**

Kalsifiye Tendinit, kalsiyum hidroksiapatit kristallerinin tendon içinde yerleşmesidir [66]. Bu olay büyük eklemlerin birçoğunun çevresinde görülmektedir. Bu hastalığın nedeni tam olarak bilinmemektedir. Kendi kendini sınırlayan ağrı ve hareket kısıtlılığına yol açmaktadır. Genellikle 30 - 50 yaş aralığındaki kişileri etkiler [66]. Kadınlarda erkeklerden daha sık görülür. Olguların %25'i her iki omuz ekleminde görülür. Hastaların çoğu masa başı çalışanlar veya ev kadınlarıdır. Sağ omuz tarafında tutulumu daha sıktır. Kalsifiye tendinit oluşma ve çözülme sürecini içeren üç evreden oluşmaktadır. İlk evrede, hastalık tesadüfen fark edilir. Hastalık bölgesinde İltihaplanma yoktur. Bu evrede ekleme kalsiyum çökmesi geri dönüşümlüdür. İkinci evrede, ağrı şiddetli ve ani başlar. Hasta kolunu muayene ettirmek istemez. Kol nötral düzlemde sabit kalmıştır. Üçüncü evrede radyografi görüntüleme yöntemlerinde tespit edilir. İyileşme ve tamir dönemidir. Eklem ve hareket kısıtlılığı olabilir.

Ağrı en önde gelen şikayettir. Özellikle omuz ekleminin ön tarafında ağrı olur ve kola yayılır. Hasta aktif veya pasif olarak abduksiyon hareketini yapamaz.

Kalsiyum çöküntülerinin direkt radyo grafide görülmesi tanı için yeterlidir. Çekilen grafilerde humerus başı üzerinde supraspinatus tendon hizasında çizgi şeklinde kalsiyum çöküntüsü görülür.

İlk evrede tedavi gerekmezken, ağrılı dönemde uzuvların kullanımı sınırlandırılır ve kol askısı, SOİD ilaçlar, bölgesel buz uygulamaları; üçüncü evre kronik evre olarak da bilinir, sıcak ve terapötik ultrason, ekstrakorporial şok dalga terapisi (ESWT) uygulanır. Tedavinin yetersiz kaldığı durumlarda bölgesel steroid uygulamalarına geçilir. Dirençli vakalarda cerrahi müdahaleler uygulanabilir.

#### **2.5 Omuz Fizyoterapi Hareketleri**

Omuz fizyoterapi hareketleri, klasik rehabilitasyon ve ev programı için omuz rahatsızlıklarında fizyoterapistler tarafından hastalarına uygulanır. Bu hareketler çalışmamız kapsamında 7 adet ile belirlenmiştir. Bu hareketler ayrıca veri setimizde bulunan hareketlerdir ve açıklanma sıralaması veri seti etiket verme sırasıyla verilmiştir.

### **2.5.1 Wand Egzersizi Omuz Fleksiyonu:**

Wand Egzersizi omzun çeşitli yönlerdeki hareketini korumak ve geliştirmek amacıyla yapılmaktadır. Wand Egzersizi ile omuz fleksiyonunda (Şekil 3.1 Hareket-3 alanında görüldüğü gibi) hasta ellerine arasına aldığı sopayla vücudu yere 90° dik tutarak, omuz eklemine 0° açıklıktan 180° açıklığa kadar dirseğini ve bileğini bükmeden açması ve bu pozisyonda 10 saniye kadar bekledikten sonra omzun açıklığını tekrar 0° getirmesidir. Bu sayede omuz fleksiyon açıklığı sopa desteğiyle gözlemlenir ve test edilir.

### **2.5.2 Wand Egzersizi Omuz Abduksiyonu:**

Wand ile omuz abduksiyonu Şekil 3.1 Hareket-4 alanında görüldüğü gibi bir sopa yardımı ile omzun 0°'den yaklaşık 180°'ye açılması, eklem açıklığının test edilmesidir. Bu egzersizde hasta elleri ile sopayı her iki uçtan yere paralel olarak vücuduna yakın pozisyonda tutar. Vücudunu yere 90° dik tutar. Eklem açıklığı test edilen tarafa doğru vücudun pozisyonunu bozmadan omzunu 180°'ye getirir. Yaklaşık 5 saniyeye kadar bu pozisyonda bekler ve omuz tekrar başlangıç pozisyona döndürülerek hareket tamamlanır. Bu test ile omuz abduksiyon açıklığı gözlemlenir ve test edilir.

### **2.5.3 Omuz Posterior Kapsül Germe:**

Omuz Posterior Kapsül germe hareketi Şekil 3.1 Hareket-5 alanında görüldüğü gibi omuz hareketi yapılacak kolun dirseği diğer elle desteklenerek vücuda doğru itilir. Bu germe noktasında 5-10 saniye beklenir ve hareket başlangıç pozisyonuna gelinerek bitirilir.

### **2.5.4 90° Omuz Fleksiyonu:**

Hasta Şekil 3.1 şeklinde Hareket-6 alanında görüldüğü gibi vücudu 90° yere dik pozisyondayken, eline almış olduğu ağırlık ile omuz eklemine 0°'den yaklaşık 90°'ye kadar kaldırıp yaklaşık 5 saniye kadar bu pozisyonda beklenir. Bu noktada kol ile vücut arası açıklık 90° olmalıdır. Daha sonra başlangıç pozisyonuna dönülür. Bu egzersizle omzun 90° fleksiyonu gözlemlenir ve test edilir.

### **2.5.5 90° Omuz Abduksiyonu:**

Hasta Şekil 3.1 şeklinde Hareket-8 alanında görüldüğü gibi vücudu 90° yere dik pozisyondayken, eline almış olduğu ağırlık ile omuz eklemine 0°'den yaklaşık 90°'ye kadar kaldırıp yaklaşık 5 saniye kadar bu pozisyonda beklenir. Bu noktada kol ile vücut arası açıklık 180° olmalıdır. Daha sonra başlangıç pozisyonuna dönülür. Bu egzersizle omzun 90° abdüksiyonu gözlemlenir ve test edilir.

### **2.5.6 Eksternal Rotasyon Yönünde Germe:**

Hasta Şekil 3.1 şeklinde Hareket-9 alanında görüldüğü gibi oturur pozisyondayken vücudunun üst kısmı yere 90° dik pozisyondayken. Hasta bileğinden dirseğine kadar bir masa yardımıyla destek almaktadır. Bu hareket sırasında masadan destek aldığı ön kolun hareket etmemesi önemlidir. Yere göre 90° duruşta olan vücut yaklaşık 180° pozisyona getirilerek, bu pozisyonda 20 saniye beklenir. Bu sayede omzun dış rotasyonu gözlenir ve test edilir.

### **2.5.7 Dirsekler Fleksiyonda Skapular Retraksiyon:**

Hasta Şekil 3.1 şeklinde Hareket-12 alanında görüldüğü gibi yere dik 90° pozisyonda kolları gövdeye bitişik, dirsek dik açıda iki eliyle bantları tutarak harekete başlar. Dirseklerin dik açısı korunarak, el bilekleri gövdeye doğru yaklaştırılır ve bu pozisyonda 5 saniye beklenerek, dirsekler fleksiyondayken skapular retraksiyon gözlemlenir ve test edilir.

### 3. VERİ SETLERİ

Tezimiz kapsamında oluşturulmuş 4 farklı veri seti bulunmaktadır. Bu veri setlerinin özellikleri bu bölümde açıklanacaktır.

Veri setleri Hacettepe-1, Hacettepe-2, Hacettepe-3 ve Hacettepe-4 olarak isimlendirilmiştir. Bu veri setlerini birbirinden ayıran farklar aşağıdaki gibidir:

- Ortam (hastane ortamı, ev ortamı),
- Işık (az ışık veya çok ışık),
- Uzaklık (Kinect kamerasının kullanıcıya olan uzaklığı),
- Kullanıcı Özellikleri (egzersiz hareketini yapan kişilerin boy, kilo ve yaş olarak farklılaşması)

Hacettepe Üniversitesi Fizyoterapi ve Rehabilitasyon Bölümü öğretim elemanlarının katkılarıyla omuz fizik tedavi ve rehabilitasyonu için kullanılan egzersiz hareketleri belirlenmiştir. Bu egzersiz hareketleri ve tezimiz kapsamındaki kodları aşağıda belirtilmiştir:

- (A3) - Wand Egzersizi (Omuz Fleksiyonu),
- (A4) - Wand egzersizi (Omuz Abduksiyonu),
- (A5) - Omuz Posterior Kapsül Germe,
- (A6) - 90° Omuz Fleksiyonu,
- (A8) - 90° Skapular Düzlemde Omuz Elevasyonu,
- (A9) - Eksternal Rotasyon Yönünde Germe,
- (A12) - Dirsekler Fleksiyonda Skapular Retraksiyon.

Veri setinde yer alan hareketler hakkında kuramsal bilgi ve hareketlerin nasıl yapılması gerektiğine dair bilgiler Bölüm 2.5 bölümünde verilmiştir. Veri setlerimizde de bulunan bu egzersiz hareketlerini Şekil 3.1 şeklinden inceleyebilirsiniz.



Şekil 3.1. Veri Seti

Tezimiz kapsamında oluşturulan dört adet veri seti ve bunlarla ilgili özellikler bu bölümde açıklanmıştır. Bu bölümde ek olarak, veri setinin alınması aşamasında kullanılan Kinect için ideal ortamdaki, tezimiz kapsamında RGB-D veri alma ve kaydetme işlemleri için geliştirilmiş olan yazılımdan ve veri setinin organizasyonundan bahsedilecektir 3.2.3 Bölümü.

### 3.1 Hacettepe Omuz Veri Seti - 1

Bu veri seti klinik ortamda ve normal ışıkta (gün ışığı girmeyen, yoğun lamba aydınlatmalı ortam) oluşturulmuştur. Veri setinde yer alan bu hareketler, Hacettepe Üniversitesi Fizyoterapi ve Rehabilitasyon Bölümü fizyoterapistleri, asistanları ve öğrencileri tarafından yapılmıştır ve veri madenciliği algoritmaları kullanarak bu hareketler modellenmiştir. Veri setinde yer alan hareketler, ilgili sınıfa ait pozitif egzersiz örneklerini temsil etmektedir.

Veri setinin oluşturulmasında 24 - 35 yaş aralığındaki 6 kadın, 5 erkek olmak üzere 11

kişiden yararlanılmıştır. Bu veri seti, Kinect XBOX 360 kamera ile KYM (RGB) resmi, derinlik resmi ve kemik konum verilerinden oluşturulmuştur. Kayıt alınan bireylerin kilo, boy, yaş dağılımlarında farklılıklar göstermesine özen gösterilmiştir. Her egzersiz hareketi için 22 kayıt olmak üzere toplamda 264 adet egzersiz kaydı oluşturulmuştur, yani her kişi bir hareketi iki tekrar yapmıştır. Bu egzersizlerin literatürdeki isim, sayı ve tezi-miz kapsamında verilen egzersiz kodlarına Çizelge 3.1 tablosundan erişilebilir.

Egzersiz Adı	Egzersiz Kodu	Kayıt Sayısı
Wand Egzersizi (Omuz Fleksiyonu)	A3	22
Wand Egzersizi (Omuz Abduksiyonu)	A4	22
Omuz Posterior Kapsül Germe	A5	22
90° Omuz Fleksiyonu	A6	22
90° Skapular Düzlemde Omuz Elevasyonu	A8	22
Eksternal Rotasyon Yönünde Germe	A9	22
Dirsekler Fleksiyonda Skapular Retraksiyon	A12	22

Çizelge 3.1. Hacettepe Omuz Veri Seti - 1 Egzersiz Sayıları ve Kodları

Veri seti hiyerarşik bir yapıda dosyalanmıştır. Bu şekilde bir dosyalama ve kayıt işlemi yapılarak veri setinin daha sonraki çalışmalarda kolay okunabilirliği hedeflenmiştir. Veri setinin ana dosya dizini hareket kaydı alınan kişilere göre tasarlanmıştır. Örneğin; ana dosya dizininde S1, S2, S3..., S13 şeklinde dosyalama kişileri göstermektedir. Buradaki kişi klasörü (S1), ilgili fizyoterapistin yapmış olduğu 7 hareketi içerir.

Bu kişi klasöründen herhangi biri seçildiğinde ise; A3\_1, A3\_2, ..., A12\_1, A12\_2, A12\_3 şeklinde her bir hareketin verilerini içeren bir dosyalama ile karşılaşılır. Buradaki "A3\_1" gibi klasörlerde A3 kodundaki hareketi yani "Wand Egzersizi Omuz Fleksiyonu" egzersizini temsil etmektedir. "A3\_1" ve "A3\_2" gibi dosyalama şekli ise, A1 hareketinin birinci ve ikinci tekrarı olarak nitelendirilmektedir. Hareket klasörü (A1\_1), içerisinde her çerçeveye karşılık gelecek şekilde alınmış olan RGB resmi, derinlik resmi ve konum bilgilerini içeren metin dosyalarını içerir. Her kare ardışık şekilde artan sayılarla temsil edilmiştir. Veri setinin dosyalama yapısının detaylarına ilişkin çizelgelere ?? ek bölümünden erişebilir.



Veri setinin özelliklerini özetlemek gerekirse;

- Ortam : Klinik
- Işık : Normal ışık (Gün ışığı girmeyen ortam, yoğun aydınlatmalı ortam)
- Uzaklık : Kinect kamera yerden 70 cm. yukarıda ve kullanıcı ile 2 m. mesafede konumlandırıldı.
- Kullanıcılar : 24 - 35 yaş aralığındaki 11 kişi (6 kadın, 5 erkek).
- Veri Türü : YKM (RGB) resim, derinlik resmi, uzaklık konum verisi.
- Veri Sayısı : 265

### **3.1.1 Hacettepe Omuz Veri Seti - 2**

Bu veri seti Bölüm 3.1 bölümünde belirtilen aynı ortam ışık, uzaklık ve veri türü ile oluşturulmuştur; ancak kullanıcı ve yapılan hareket sayısı yönünden farklılık göstermektedir.

Veri setinin oluşturulmasında 24 - 35 yaş aralığındaki 6 kadın, 5 erkek olmak üzere 11 kişiden yararlanılmıştır. Bu veri seti, Kinect XBOX 360 kamera ile, KYM (RGB) resmi, derinlik resmi ve kemik konum verilerinden oluşturulmuştur. Kayıt alınan bireylerin kilo, boy, yaş dağılımlarında farklılıklar göstermesine özen gösterilmiştir. Her egzersiz hareketi için farklı sayıda kayıt olmak üzere toplamda 135 adet egzersiz kaydı oluşturulmuştur.

Bu egzersizlerin literatürdeki isim, sayı ve tezimiz kapsamında verilen egzersiz kodlarına Çizelge 3.2 tablosundan erişilebilir.

Egzersiz Adı	Egzersiz Kodu	Kayıt Sayısı
Wand Egzersizi (Omuz Fleksiyonu)	A3	11
Wand Egzersizi (Omuz Abduksiyonu)	A4	11
Omuz Posterior Kapsül Germe	A5	11
90° Omuz Fleksiyonu	A6	11
90° Skapular Düzlemde Omuz Elevasyonu	A8	12
Eksternal Rotasyon Yönünde Germe	A9	11
Dirsekler Fleksiyonda Skapular Retraksiyon	A12	12

Çizelge 3.2. Hacettepe Omuz Veri Seti - 2 Egzersiz Sayıları ve Kodları

Veri setinin özelliklerini özetlemek gerekirse;

- Ortam : Klinik
- Işık : Normal ışık (Gün ışığı girmeyen ortam, yoğun aydınlatmalı)
- Uzaklık : Kinect kamera yerden 70 cm. yukarıda ve kullanıcı ile 2 m. mesafede konumlandırıldı.
- Kullanıcılar : 30 yaş aralığındaki 11 kişi (6 kadın, 5 erkek).
- Veri Türü : YKM (RGB) resim, derinlik resmi, uzaklık konum verisi.
- Veri Sayısı : 135

### 3.1.2 Hacettepe Omuz Veri Seti - 3

Bu veri seti ev ortamında ve gün ışığında oluşturulmuştur. Veri setinde yer alan bu hareketler, hareketleri daha önce görmemiş kişilerin hareketleri ViTES uygulamasından öğrenerek tekrar etmesiyle oluşturulmuştur ve veri madenciliği algoritmaları kullanarak bu hareketler modellenmiştir. Veri seti 30 yaşlarındaki bir erkek tarafından toplamda 87 egzersiz hareketi ile oluşturulmuştur. Bu egzersizlerin literatürdeki isim, sayı ve tezimiz kapsamında verilen egzersiz kodlarına Çizelge 3.3 tablosundan erişilebilir.

Egzersiz Adı	Egzersiz Kodu	Kayıt Sayısı
Wand Egzersizi (Omuz Fleksiyonu)	A3	12
Wand Egzersizi (Omuz Abduksiyonu)	A4	12
Omuz Posterior Kapsül Germe	A5	13
90° Omuz Fleksiyonu	A6	13
90° Skapular Düzlemde Omuz Elevasyonu	A8	12
Eksternal Rotasyon Yönünde Germe	A9	13
Dirsekler Fleksiyonda Skapular Retraksiyon	A12	12

Çizelge 3.3. Hacettepe Omuz Veri Seti - 3 Egzersiz Sayıları ve Kodları

Veri setinin özelliklerini özetlemek gerekirse;

- Ortam : Ev
- Işık : Az ışık (Gün ışığı girmeyen gece, loş aydınlatmalı)
- Uzaklık : Kinect kamera yerden 70 cm. yukarıda ve kullanıcı ile 2.5 m. mesafede konumlandırıldı.
- Kullanıcılar : 30 yaş aralığındaki 1 erkek.
- Veri Türü : Uzaklık konum verisi.
- Veri Sayısı : 87

### 3.1.3 Hacettepe Omuz Veri Seti - 4

Bu veri seti ev ortamında ve gün ışığında oluşturulmuştur. Veri setinde yer alan bu egzersiz hareketleri, hareketleri daha önce görmemiş kişilerin hareketleri VİTES uygulamasından öğrenerek tekrar etmesiyle oluşturulmuştur ve veri madenciliği algoritmaları kullanılarak bu hareketler modellenmiştir. Veri seti 30 - 60 yaş aralığındaki 2 kadın, 3 erkek olmak üzere 5 kişiden yararlanılmıştır. Bu verisi, Kinect XBOX 360 kamera ile,

derinlik kemik konum verilerinden oluşmaktadır. Kayıt edilen bireylerin kilo, boy, yaş dağılımlarında farklılıklar göstermesine özen gösterilmiştir. Kişiler hareketi 10 tekrar şeklinde yapıp 7 seçilmiş hareketi yapmışlardır. Toplamda 349 veri oluşturulmuştur. Bu egzersizlerin literatürdeki isim, sayı ve tezimiz kapsamında verilen egzersiz kodlarına Çizelge 3.4 tablosundan erişilebilir.

Egzersiz Adı	Egzersiz Kodu	Kayıt Sayısı
Wand Egzersizi (Omuz Fleksiyonu)	A3	50
Wand Egzersizi (Omuz Abduksiyonu)	A4	49
Omuz Posterior Kapsül Germe	A5	50
90° Omuz Fleksiyonu	A6	50
90° Skapular Düzlemde Omuz Elevasyonu	A8	50
Eksternal Rotasyon Yönünde Germe	A9	50
Dirsekler Fleksiyonda Skapular Retraksiyon	A12	50

Çizelge 3.4. Hacettepe Omuz Veri Seti - 4 Egzersiz Sayıları ve Kodları

- Ortam : Ev
- Işık : Çok ışık (Gün ışığı)
- Uzaklık : Kinect kamera yerden 60 cm. yukarıda ve kullanıcı ile 3.2 m. mesafede konumlandırıldı.
- Kullanıcılar : 30 - 60 yaş aralığındaki 2 kadın, 3 erkek.
- Veri Türü : Uzaklık konum verisi.
- Veri Sayısı : 349

### 3.1.4 Hacettepe Omuz Veri Seti - 5

Bu veri seti fizyoterapi bölümünde ve gün ışığında oluşturulmuştur. Veri setinde yer alan bu egzersiz hareketleri, hareketleri daha önce görmemiş ve VİTES uygulaması üzerinden öğrenip kayıt alınırken, ikinci gruba ise bu hareketler fizyoterapist tarafından öğretilmiş

ve kayıtlar yine ViTES uygulaması ile alınmıştır. (Böyle bir ayrıma gidilerek bu veri seti farklı testlerde kullanılmıştır, detaylar için 7 bölümünü inceleyebilirsiniz.) Veri seti 18 - 45 yaş aralığındaki 6 kadın, 4 erkek olmak üzere 10 kişiden yararlanılmıştır. Bu verisi, Kinect XBOX 360 kamera ile, derinlik kemik konum verilerinden oluşmaktadır. Kayıt edilen bireylerin kilo, boy, yaş dağılımlarında farklılıklar göstermesine özen gösterilmiştir. Kişiler hareketi 1 tekrar şeklinde yapıp 7 seçilmiş hareketi yapmışlardır. Toplamda 70 veri oluşturulmuştur. Bu egzersizlerin literatürdeki isim, sayı ve tezimiz kapsamında verilen egzersiz kodlarına Çizelge 3.5 tablosundan erişilebilir.

Egzersiz Adı	Egzersiz Kodu	Kayıt Sayısı
Wand Egzersizi (Omuz Fleksiyonu)	A3	10
Wand Egzersizi (Omuz Abduksiyonu)	A4	10
Omuz Posterior Kapsül Germe	A5	10
90° Omuz Fleksiyonu	A6	10
90° Skapular Düzlemde Omuz Elevasyonu	A8	10
Eksternal Rotasyon Yönünde Germe	A9	10
Dirsekler Fleksiyonda Skapular Retraksiyon	A12	10

Çizelge 3.5. Hacettepe Omuz Veri Seti - 5 Egzersiz Sayıları ve Kodları

- Ortam : Klinik
- Işık : Az ışık (Gün ışığı)
- Uzaklık : Kinect kamera yerden 60 cm. yukarıda ve kullanıcı ile 2.6 m. mesafede konumlandırıldı.
- Kullanıcılar : 30 - 60 yaş aralığındaki 10 kişi (6 kadın, 4 erkek).
- Veri Türü : Uzaklık konum verisi.
- Veri Sayısı : 70

Tezimiz kapsamında oluşturulan veri setlerine

### 3.2 RGB-D Fizyoterapi Egzersiz Verisinin Ön Analiz Edilmesi

Fizyoterapi egzersizleri kullanıcılar tarafından yapılırken, egzersizlerin yapısından kaynaklanan RGB-D kameranın göremediği eklem noktaları olabilmektedir. Yapılan egzersiz, kullanıcının yan durarak bir egzersiz yapması gerektiğinde arkada kalan kolun eklem noktalarının algılanamaması gibi durumlar buna örnektir. Bu durumda veri setinde 20 adet eklem konum verisinden daha eksik kemik tespiti sonucu doğacaktır. Bu durumda kaydedilen eklem sayısında tutarsızlığa ve veri setindeki uyumsuzlukları neden olur.

Tanınmayan eklemlerden dolayı, hareketi yorumlamada sorunlar oluşmaktadır. Örneğin; öznitelik çıkarımı aşamasında kemik sayısındaki değişim öznitelik uzayının boyutunda değişimlere neden olur ve bu sınıflandırmada oluşturduğunuz eğitim verisinde sapmalara (RGB-D eklem verilerinin sırasının kayması) neden olmaktadır. Bu sapmalarla sınıflandırıcı eğitimi çok yanlış şekilde yapmanıza sebep olabilir. Bu şekilde çok düşük eğitim verisi performansı elde edilebilir.

Tespit edilmeyen kemiğin yok sayılması durumunda öznitelik uzayındaki değişimi tespit etmek hareket bazlı olarak farklı sınıflandırıcı eğitimleri yapmak çok zor ve zaman harcıyıcı bir yöntem olarak gerçek zamanlı bir sistemde mümkün değildir. Ayrıca, tespit edilmeyen kemiğin yerine sıfır(0) veya belirsiz bir değer atamak uzayda ona bir konum vermeye yol açtığından bu da sınıflandırmada büyük sorunlara yol açmaktadır. Örneğin, eklem noktasının birdenbire A noktasından B noktasına sıçraması gibi ancak onun bağlantılı olduğu kemiklerin bu pozisyonun çok uzağında olması gibi.


Bu sorunu aşmak için, Kinect'ten veri elde ederken çalışma kapsamında kullanmış olduğumuz Microsoft Kinect SDK 1.8'in konfigürasyonlarını incelemek gerekmiştir. RGB-D kamera yapısı ve içerisinde bulunan algoritmalar gereği, bulamadığı kemiğin konumunu tahmin etme özelliğindedir. Bunu yaparken ilgili eklemin bir önceki konumu ve ilgili eklemin bağlı olduğu diğer kemiklerin konumuna göre kamera tarafından bulunamayan eklem noktasının konumu tahmin edilir. Bu sorun veri seti oluşturulma aşamasında tespit edilmiş ve her kare (frame) için 20 kemiğin tespit edildiğinden emin olunmuştur. Ek olarak, veri seti gözden geçirilerek, yanlış kayıtlar ve alınamayan kayıtlar silinerek veri

işlemeye uygun hale getirilmiştir.


### **3.2.1 Fizyoterapi Hareketlerinin Kaydedilmesi**

Tezimizin ilk zamanlarında (ViTES uygulaması geliştirilmeden önce) omuz fizyoterapi hareketlerinin kayıt edilmesi işlemi kapsamında, C# dili ve Windows Form teknolojisi kullanılarak bir masaüstü uygulaması geliştirilmiştir ve Hacettepe Omuz Veri Seti - 1 ve Hacettepe Omuz Veri Seti - 2 bu uygulama kullanılarak alınmıştır.


Bu yazılım sayesinde RGB resmi, derinlik resmi ve derinlik konum verileri kaydedilmiştir. Saniyede 30 kare (frame) veri sağlama yeteneği sahip olan Kinect cihazından veri almak için bu mimariye ve hıza uygun şekilde verilerin alınması ve kaydedilmesi evrelerinde paralelleştirme kullanılarak bir yazılım ortaya çıkartılmıştır. Bu yazılımın ekran görüntüsüne Şekil 3.3 şeklinde yer verilmiştir. Uygulama başlatıldıktan sonra Kinect kamera bağlı değil veya bağlantıda herhangi bir sorun oluşmuşsa kullanıcıyı uyararak bağlantıyı kurmasını beklediğini belirten bir uyarı mesajı vermektedir. Bağlantı başarılı bir şekilde sağlandığında "Connection ID" yazan kısım dolu olarak gelmekte ve bağlantı durumunun "Connected" olarak bağlı olduğu bilgisi verilmektedir. Yazılımın kayıt işlemleri sırasında katkılarında birisi de kaydı alınacak kişinin kemikler tanınıp/tanınmadığını tespit edip, hareketin kayıt alınmaya hazır olup olmadığını belirtmesidir. Kamera karşısında hareketi yapmaya başlayacak olan kullanıcının kamera tarafından tanınmasıyla derinlik görüntüsü renklendirilmektedir ve kayıt işlemine hazır olduğu bilgisi verilmektedir. Bu aşamadan sonra kayıt alacak kullanıcının "Hasta Adı" ve "Hareket Adı" alanlarını doldurmasıyla hareket belirtilen dosyalama yapısıyla kayıt altına alınır. Örneğin, hasta adı "Ahmet" ve hareket adı "A1" olarak verildiğinde "/KÖK DİZİN/Ahmet/A1" adında bir klasör oluşturularak RGB resmi, derinlik resmi ve derinlik konum verileri (txt) olarak frame frame bu dizine artan indislerle kayıt altına alınır. Son olarak, yazılım "single thread" olarak çalışmaktaydı bu da hareketlerin dosyaya kayıt işlemlerinde çok zaman kaybına neden oluyordu. Uygulamanın "multi-thread" olarak düzenlenmesiyle bu sorun ortadan kaldırılmıştır.



Şekil 3.2. Kinect Tanılanan Kemikler



Şekil 3.3. Kinect Görüntüleme ve Kaydetme Uygulaması



Şekil 3.4. Veri Seti Toplama Kinect Konum Konfigürasyonu



### 3.2.2 Kinect Tanınan Kemikler

İnsan anatomisine bakıldığında 20 farklı hareket noktası bulunmaktadır. Microsoft Kinect XBOX 360, üzerinde bulunan kızılötesi 2 kamera sayesinde (kızılötesi verici ve derinlik sensörü) insanın ayakta 20 farklı eklem konumunu ve oturarak ise 7 eklem noktasını bir işaretçi kullanmaksızın tanıma yeteneğine sahiptir [54]. Bu tanılan eklem verilerine ait, RGB resmi, derinlik resmi ve derinlik konum verileri bulunmaktadır. Bu veriler içerisinde yer alan derinlik konum verileri çalışmamızın ana konusunu oluşturmaktadır ve incelemeler bu veriler üzerinden yürütülmüştür. Tanınan eklem vücut noktalarına Şekil-3.2 şeklinde yer verilmiştir.

### 3.2.3 Fizyoterapi Hareketlerinin Kaydedilme Konfigürasyonu

Kinect kamera için önerilen ve birçok kayıt alma işleminde test edilmiş konfigürasyonlar incelenmiştir. Bu incelemeler sonucunda en iyi kayıt alma ölçümleri Kinect kameranın yerden 0.7 metre yükseklikte sabitlendiği bir pozisyonda bulunmalıdır. Kaydı alınan kişi ile kamera arasında 2 metre bir mesafe olmalıdır ve Kinect kamera ile kaydı alınan kişi 0.7 metre x 0.7 metrelik bir alan içerisinde bulunmalıdır. Fizyoterapi hareketlerinin kaydedilmesine detaylı şekilde modelleyen çizelge Şekil 3.4 şeklinde belirtilmiştir.

VİTES uygulaması ile alınan Hacettepe Omuz Veri Seti - 4'de kaydedilme konfigürasyonu değiştirilerek bu etki araştırılmıştır. Kinect yerden 55 cm. yukarıya konumlandırılıp, Kinect ile kullanıcı arasındaki mesafe 3m.'ye kadar çıkartılmıştır. Bu şekilde de başarılı şekilde kayıt almak ve hareketlerin doğru tespit edildiği gözlemlenmiştir. Bu şekilde tezimiz kapsamında denenmiş olan iki konfigürasyonu da önermekteyiz.

## 4. SINIFLANDIRMA

Omuz tedavisi için önerilen 7 fizyoterapi egzersizlerini içeren veri setimizde, bu egzersizleri tanılamak için gözetimli sınıflandırma yöntemleri kullanılmıştır. Hasta tarafından yapılan fizyoterapi egzersizlerinin hangi egzersize ait olduğun tespiti ve hasta tarafından ilgili egzersizin ne doğrulukta yapıldığının saptanması amaçlı gözetimli sınıflandırma yöntemleri üzerinde çalışılmıştır. Bu bölümde veri madenciliği temelleri, sınıflandırma problemi, gözetimli sınıflandırıcılar hakkında teorik bilgiler verilecektir. Bu bölümde son olarak, oluşturulan veri seti için farklı gözetimli sınıflandırma yöntemleri karşılaştırılarak, oluşturulan sınıflandırma modelleri test edilmiş ve en iyi gözetimli sınıflandırıcı yöntemlerinin belirlenmesi konusunda bilgiler sunulacaktır.

### 4.1 Veri Madenciliği

Veri madenciliği, büyük veri havuzlarında yer alan verilerden yararlı bilgileri otomatik keşfetme işlemidir. Veri madenciliği teknikleri, başka türlü bilinmeyen yeni ve kullanışlı modeller bulmak için büyük veri tabanlarını araştırmak üzere dağıtılmıştır. Büyük miktardaki veriler arasındaki desenleri bulma, düzensizliklerin, değişimlerin, ilişkilerin keşfedilmesi, yeni bir veriyi bulma, gelecekte olması muhtemel veriyi tahmin etme gibi çıkarımlar yapılmasına imkan sağlar. Örneğin yeni gelen bir müşterinin bir mağazada 100 dolardan daha fazla harcayacağını tahmin edilmesi gibi. Veri madenciliği, büyük miktarda veriyi işlemek için geleneksel veri analizi yöntemlerini karmaşık algoritmalar ile harmanlayan bir teknolojidir. Ayrıca, yeni veri türlerini keşfetmek ve analiz etmek ve eski veri türlerini yeni yollarla analiz etmek için önemli fırsatlar da açtı [56].

Veri madenciliği teknikleri, müşteri profili oluşturma, hedefli pazarlama, iş akışı yönetimi, mağaza düzeni, sahtekarlık tespiti ve kredi analizleri gibi çok çeşitli iş zekası uygulamalarını desteklemek için kullanılır.

Tıp, Bilim ve Mühendislik Araştırmacıları tıp, bilim ve mühendislik alanında hızla yeni önemli keşiflerin anahtarı olan verileri toplamaktadır. Örneğin, Dünya'nın iklim sistemi hakkında anlayışımızı geliştirmeye yönelik önemli bir adım olarak, NASA sürekli olarak yer yüzeyine, okyanuslara ve atmosfere karşı küresel gözlemler üreten bir dizi dünya yörüngesel (earthorbiting) uyduları kullanmıştır. Bununla birlikte, verinin büyüklüğü ve

mekânsal-doğası gereği, geleneksel yöntemler genellikle bu veri kümelerini analiz etmek için uygun değildir. Veri madenciliğinde geliştirilen teknikler, "Dünya ısınmasına kuraklık ve kasırgalar gibi ekosistem rahatsızlıklarının sıklığı ve yoğunluğu arasındaki ilişki nedir?" gibi soruları yanıtlarken dünya bilim insanlarına yardımcı olabilir. Bu sorulardan bazıları "Yüzey yağışları ve sıcaklıkları okyanus yüzey sıcaklığından nasıl etkilenir?" ve "Bir bölge için büyüme mevsiminin başlangıcını ve sonunu ne kadar iyi tahmin edebiliriz?" şeklindedir.

Başka bir örnek olarak, moleküler biyolojideki araştırmacılar, genlerin yapısını ve işlevini daha iyi anlamak için toplanan büyük miktardaki genomik verileri kullanmayı amaçlıyorlar. Geçmişte, moleküler biyolojide geleneksel yöntemler, bilim adamlarının belirli bir deneyde bir seferde sadece birkaç gen üzerinde çalışmasına izin veriyordu. Mikroarray teknolojisindeki son gelişmeler bilim adamlarının binlerce farklı genin davranışlarını çeşitli durumlarda karşılaştırmasını sağlamıştır. Bu tür karşılaştırmalar, her genin işlevini belirlemeye yardımcı olabilir ve belki de bazı hastalıklardan sorumlu genleri izole edebilir. Bununla birlikte, gürültülü ve yüksek boyutlu veri niteliği, yeni veri analizi türleri gerektirir. Gen dizisi verilerinin analiz edilmesine ek olarak, veri madenciliği, protein yapısı tahmini, çoklu dizi hizalama, biyokimyasal yollar ve filogenetiklerin modellenmesi gibi diğer önemli biyolojik zorlukları ele almak için de kullanılabilir.





Figure 1.1. The process of knowledge discovery in databases (KDD).

Şekil 4.1. Bilgi keşfi süreci ve veri madenciliği



Şekil 4.2. Bilgi keşfi süreci ve veri madenciliği

Veri madenciliği alanları genel olarak dört grupta incelenebilir. Bunlar kümeleme, kestirimsel modelleme, eşleştirme kuralları madenciliği, anomali tespittir[56]. Bu alanlardan, kümeleme ve kestirimsel modellemenin alt alanı olan sınıflandırma problemi tez kapsamında açıklanacaktır.

## 4.2 Kümeleme

Kümeleme problemi, birbiriyle yakından ilişkili gözlem gruplarını bulmaya çalışır, böylece aynı kümeye ait gözlemler, diğer kümelenmelere ait gözlemlerden daha fazladır. Bu sayede öznitelik uzayını azaltma da kullanılabilir. Tezimiz kapsamında omuz verileri birçok çerçeveden oluşmaktadır. Bu çerçevelerden birbirine çok yakın olan çerçeveler kümelenecek, içerisinde o kümeyi en iyi temsil eden çerçeve seçilerek, öznitelik uzayı düşürülmüştür.

### 4.2.1 K-means Kümeleme Yöntemi

K-means tekniği, kümeleme problemini çözen, prototip tabanlı, denetimsiz öğrenme yöntemlerindedir. Algoritma tek seviyeli bir bölümlendirme oluşturur. K-means algoritmasının genel çalışma prensibi, n adet veri objesinden oluşan bir veri kümesini, giriş parametresi olarak alınan bir k sayısına göre, k adet kümeye bölmektir. Algoritmanın temel mantığı küme içi benzerliğin en çok, kümeler arası benzerliğin ise çok düşük olmasını sağlamaktır.

K-means algoritması iteratif bir yaklaşımdadır. İlk cendroid değerleri genellikle rastgele rastgele atanır ve hata düşürülerek bu noktaların değişimi sağlanır. Grup içi noktaların uzaklıkları hesaplanırken birçok uzaklık bulma ölçütleri kullanılabilir.

K-means algoritması, rastgele seçilen K adet orta nokta seçimiyle başlar. Kümelerdeki her nokta 4.2.3 bölümünde belirtilen uzaklık hesabına göre, kendisine en yakın merkez noktanın kümesine atanır. Daha sonra kümelerin yeni merkezi, atanan noktaların ortalaması alınarak yeniden hesaplanır ve yeniden her bir noktanın güncellenen merkezlere göre uzaklığı hesaplanır bu şekilde kümelenen noktalarda değişimler olabilir. Bu işlem, orta noktalarının değişmesi durana kadar devam eder.

K-means Algoritmasının adımları aşağıdaki gibidir:

- (1): Algoritmanın girdilerinden olan K kadar orta nokta veri setinde rastgele olarak seçilir. ( **$M_1$** ,  **$M_2$** ,  **$M_3$** , ...,  **$M_k$** ) Orta nokta hesabı 4.1 formülündeki gibi hesaplanabilir [59]:

$$M_k = \frac{1}{n_k} \sum_{i=1}^{n_k} x_{ik} \quad (4.1)$$

- (2): Küme içi değişimleri 4.2 formülündeki hesaplanabilir [60]:

$$e_i^2 = \sum_{i=1}^{n_k} (x_{ik} - M_k)^2 \quad (4.2)$$

Ayrıca K kümesini içeren tüm kare-hata küme içindeki değişimlerin toplamıdır ve bu 4.3 ile hesaplanır.

$$E_k^2 = \sum_{k=1}^K e_k^2 \quad (4.3)$$

- (3): Her bir veri kendine en yakın kümeye atanır.
- (4): Verilerin hepsi en yakın kümelere atandıktan sonra tekrar K tane küme için merkezleri hesapla.
- (5): Küme merkezlerinde bir değişiklik olmayınca kadar (2) Adım ve (3) Adımları tekrarla.

K-means algoritmasında, uzaklık hesaplama teknikleri veri setine ve veri setinin dağılımına çok bağlıdır. Yaygın olarak kullanılan uzaklık metrikleri aşağıdaki gibidir:

- Öklid Uzaklığı
- Minkowski Uzaklığı
- Manhattan Uzaklığı
- Chebyshev Uzaklığı
- Mahalanobis Uzaklığı

Bu uzaklıkların veri setimize olan etkisi (eğitim ve test veri seti, model öğrenme performansına olan etkisi), tezimizin Sonuç bölümünde 7 verilecektir.

#### **4.2.2 K-medoid Kümeleme Yöntemi**

K-medoids algoritması verilen girdi K değerine göre, veriyi K tane temsilci ile ifade etme esasına dayanır.

K-means prototiplemeyi verinin merkez noktasına olan uzaklığa göre hesaplarken, K-medoid küme içinde, kümeyi en iyi temsil eden noktaya göre, kümeden bir eleman ile temsil eder. Yani K-means ile elde edilen, kümeyi en iyi temsil eden yeni nokta kümenin bir elemanı olmayabilir. K-means algoritmasının kümeleme mantığı gereği her bir verinin yalnızca bir kümeye ait olabilmesine izin verir [61]. K-medoid algoritmasının adımları aşağıdaki gibidir [61]:

- (1): K küme sayısının belirlenmesi
- (2): Başlangıç medoidleri olarak K adet temsilci verinin seçimi
- (3): En yakın medoid X'e sahip kümeye, kalan verileri atamak
- (4): Amaç fonksiyonunu hesaplamak. (Hata kareler yöntemi ile en yakın medoidler için tüm verilerin uzaklıklarının toplamı)
- (5): Rastsal olarak medoid olmayan Y verisinin seçimi
- (6): Eğer X ile Y'nin yer değiştirmesi amaç fonksiyonunu minimize ederse, bu iki noktanın (X ile Y) yerini değiştirmek

- (7): Bu iki noktanın (X ile Y) değişmeyeceği ana kadar (3) Adım ile (6) Adım arasındaki işlemlerin tekrarlanması.

### 4.2.3 Uzaklık Ölçütleri

#### 4.2.3.1 Minkowski Uzaklığı

Normalleştirilmiş vektör uzayındaki, p sayıdaki değişken vektör içerisinden gözlem vektörleri arasındaki uzaklığın hesaplanması durumunda kullanılabilir.  $A=(A_1, A_2, A_3, \dots, A_n)$  ve  $B=(B_1, B_2, B_3, \dots, B_n)$  olmak üzere A, B noktaları arasındaki uzaklık 4.4 denklemindeki gibi hesaplanır [58]:

$$d(x_i, x_j) = \left( \sum_{k=1}^p |x_{ik} - x_{jk}|^\theta \right)^{\frac{1}{\theta}} \quad (4.4)$$

Minkowski uzaklığı, Öklid, Manhattan ve Chebyshev uzaklığının genelleştirilmiş halidir. [Denklemler-Minkowski] 'de  $m=2$  için Öklid uzaklık bağlantısı elde edilirken,  $m=1$  için Manhattan uzaklık bağlantısı, ayrıca sonsuz giderken teta ( $\theta$ ) için Chebyshev uzaklığı elde edilir.

#### 4.2.3.2 Öklid Uzaklığı

Genelde literatürde en çok bilinen ve yaygın olarak kullanılan uzaklık ölçüsüdür. İki boyutlu uzayda Pisagor teoreminin bir uygulamasıdır. Minkowski uzaklığının  $m=2$  için özelleştirilmiş halidir. Öklid uzaklık formülü 4.5 ile ifade edilmiştir.

$$p = (p_1, p_2, \dots, p_n) \quad \text{ve} \quad q = (q_1, q_2, \dots, q_n) \quad (4.5)$$

$$\sum_{i=1}^n (p_i - q_i)^2 = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (4.6)$$

$$d(A, B) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (4.7)$$

Standartlaştırılmış Öklid uzaklığı ise, Karl Pearson uzaklık ölçütü olarak da adlandırılır. Öklid uzaklığındaki her gözlem vektörünün kartezyen değerinin varyansının ağırlık

vektörü olarak kullanılmasıyla elde edilir. Standartlaştırılmış Öklid uzaklığının formülü, 4.8 ifadesiyle verilmiştir.

$$i, j = 1, 2, \dots, n \quad \text{ve} \quad x_i, x_j \in X \quad \text{olmak üzere,} \quad (4.8)$$

$$d(x_i, x_j) = \left( \sum_{k=1}^p \frac{1}{s^2} (x_{ik} - x_{jk})^2 \right)^{\frac{1}{2}} \quad (4.9)$$

#### 4.2.3.3 Manhattan Uzaklığı

İki gözlemci nokta arasındaki uzaklık, noktaların kartezyen koordinatlarının farklarının mutlak değerlerinin toplamı şeklinde ifade edilir. Literatürde City-Blok ismiyle de adlandırılmıştır. Bu ölçümde, farkların karesi alınmadığı için farklılıkların etkisi azalır [62]. Manhattan uzaklığı 4.10 'deki gibi hesaplanır.

$$d(A, B) = \sum_{k=1}^n (|A_k - B_k|) \quad (4.10)$$

#### 4.2.3.4 Chebyshev Uzaklığı

İki gözlem vektörü arasındaki farkın mutlak değerinin maksimumu, iki gözlem vektörü arasında uzaklık metriği olarak kullanılır. Chebyshev uzaklığının formülüne 4.11 ifadesinde verildiği gibidir.

$$d(x_i, x_j) = \max_{k=1, \dots, p} \{|x_{ik} - x_{jk}|\} \quad (4.11)$$

Chebyshev uzaklığı, mutlak uzaklık farklarının maksimumunu alma şeklinde hesaplandığından, veri setindeki gözlem vektörlerinin arasındaki maksimum değerler öne çıkacak şekilde vektörler öne çıkar. Değeri büyük olmayan vektörlerin öne çıkarılması mümkün olmayacaktır. Bu yüzden vektör değerleri arasında büyük farklar olan veri setlerinde sorunlara yol açabilir ve kullanılması önerilmez[62].

### 4.3 Kestirimsel Modelleme

Kestirimsel modelleme, açıklayıcı değişkenlerin bir fonksiyonu olarak hedef değişken için bir model oluşturma görevini ifade eder. İki tür kestirimsel modelleme tekniği vardır: ayrık hedef değişkenler için kullanılan sınıflandırma ve sürekli hedef değişkenler



için kullanılan regresyon. Örneğin, bir Web kullanıcısının çevrimiçi bir kitapçıda alışveriş yapıp yapamayacağını tahmin etmek, hedef değişkenin ikilik değerli olduğu için bir sınıflandırma görevidir. Aksine, bir stokun gelecekteki fiyatının tahmine edilmesi regresyon ile çözümlenir; çünkü fiyat sürekli bir özelliktir. Her iki tekniğinde amacı hedef değişkenin öngörülen ve gerçek değerleri arasındaki hatayı en aza indiren bir model öğrenmektir.

Bunların dışında Cosinüs uzaklığı, Jaccard uzaklığı, Spearman uzaklığı da literatürde yer alan uzaklık ölçütlerindedir.

#### 4.4 Sınıflandırma Problemi

Sınıflandırma problemi, verilen bir girdiye göre, bir çıktıyı tahmin etme işlemini kapsar. Çıktıyı tahmin etmek için, sınıflandırma algoritmaları bir eğitim seti içerir. Bu eğitim seti öznitelikler vektörü ve buna ait olan çıktı değerini (sınıf) içerir. Algoritma öznitelik vektörleri arasında ilişkileri öğrenerek, çıktıyı oluşturmaya çalışır.

Sınıflandırmanın amacı, bir niteliğin değerini diğer nitelikleri kullanarak verinin dağılımına göre bir model oluşturmak, bulunan modelin başarımı belirlendikten sonra niteliğin gelecekteki veya bilinmeyen değerini tahmin etmek için kullanılır. Model temelde bir fonksiyondur. Bu fonksiyon, verilen değerlerini en az hatayla öğrenmeye dayalı veri madenciliği modelleri ve algoritmaları temel alınarak oluşturulur. Modelin matematiksel olarak gösterimi 4.12'de gösterildiği gibidir. Oluşturulmuş bu fonksiyon, gelecek verilen ve eğitim setinde bulunmayan ve etiket değeri bilinmeyen bir örneğin (test verisi), etiket verisinin sonucunu bulmak için kullanılır.

$$y = f(x) \quad (4.12)$$

##### 4.4.1 Gözetimli Sınıflandırma Yöntemleri

Gözetimli Öğrenme Yöntemleri, denetimli veya kontrollü öğrenme olarak da adlandırılır. Etiketlenmiş eğitim verisi kullanılarak giriş verisi olarak sağlanan veriden sonuç kümesinin elde edilmesi temeline dayanır. Verilen X girdi kümesinden (etiketsiz veri, test verisi)

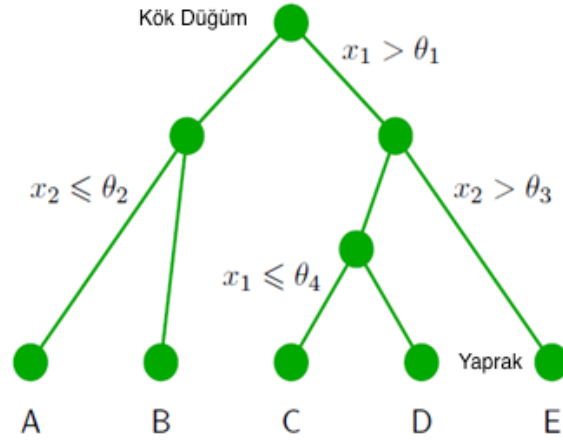
istenen  $Y$  çıktı kümesinin elde edilmesi için bir fonksiyon (haritalama fonksiyonu) öğrenilmesidir. Bu fonksiyona model adı verilir. Fizyoterapi eğitim verisi seti üzerinde gözetimli öğrenme, model öğrenme sürecini kontrol eden bir öğretmen olarak varsayılabilir. Eğitim verileri modele giriş nesnesi olarak verilir, çıkış değerleri tekrarlı olarak tahmin edilir ve öğretmen tarafından düzeltilir (fonksiyonda hata minimize edilmesi prensibi). Öğrenme süreci kabul edilebilir düzeyde performansa ulaştığında bu işlem durdurulur. (Performans artırımı için veri setinin arttırılması, yeni özniteliklerin eklenmesi vb. kullanılır.) Bu çalışmada omuz fizyoterapi hareketlerinin sınıflandırma performansları Destek Vektör Makineleri (DVM), Kalibre Edilmiş Destek Vektör Makineleri, Karar Ağaçları, K-En Yakın Komşu (KNN) ve Yapay Sinir Ağları (YSA veya MLP) sınıflandırma yöntemleri ve bunların alt türevleri ile değerlendirilecektir.

#### 4.4.1.1 Karar Ağaçları

Karar ağaçları; verileri, cevabı birbirine bağlı bir dizi soru sonucunda ağaç yapısında sorulara verilen cevaplara göre ayrıştırma tekniğidir. Her başarılı ayrıştırma sonucunda veri kümesini birbirinden farklı alt bölgelere, kendi bölümde daha benzer veriler içerecek şekilde sınıflandırmak mümkün olacaktır. Şekil 4.3 şeklilde bir karar ağacının yapısında görüldüğü gibi her bir kutucuk düğüm (node) olarak adlandırılır, İlk düğüm olarak nitelendirilebilecek düğüme "kök düğüm" (parent node), "terminal düğüm" isimleri verilmiştir, diğer düğümlere ise "çocuk düğüm" (child node), "yaprak" gibi isimlendirmeler yapılmıştır.

Karar ağaçları, her gözetimli sınıflandırıcıda temel alındığı gibi eğitim ve test aşamalarını içerir. Eğitim aşamasında, önceden etiketleri bilinen bir eğitim veri seti ile model oluşturmak amacıyla sınıflandırma algoritması eğitilir. Öğrenilen model, sınıflandırma kuralları ve fonksiyonunu içerir. Buna bu sınıflandırıcı da karar ağacı ismi de verilmektedir. Test adımında ise, Yeni bir test verisi  $x$  için (eğitim setinde yer almayan veri), kök düğümden başlayarak, bağlantı noktalarında oluşturulmuş sorular sorularak test verisinin hangi bölgeye düştüğü tespit edilir. Yani, eğitim verisinde yer almayan bir veri seti ile öğrenilmiş olan model test edilir ve başarıyı ölçülür. Eğer doğruluk, geliştirilen probleme göre kabul edilebilir ölçüde ise model sınıflandırma amacıyla tercih edilir. Karar ağaçları, her gözetimli sınıflandırıcıda temel alındığı gibi eğitim ve test aşama-

larını içerir. Eğitim aşamasında, önceden etiketleri bilinen bir eğitim veri seti ile model oluşturmak amacıyla sınıflandırma algoritması eğitilir. Belirli bir veri kümesinin sınıflandırılması, ilgili verinin bir özelliğinin değerinin kök düğüme sorulmasıyla başlar. Kök düğüm ile yaprak düğümleri birbirine bağlayan bağlantı noktalarında sorunun cevabına göre veriler ilgili yaprak düğümünün kümesine ayrıştırılır. Her soru kriteri, bölgeler arasındaki riski maksimize edecek şekilde ayrıştırılır ve en iyi ayrışmayı bulmak için her soruda bu işlemler tekrar edilir. Şekil 4.3 şeklindeki örnekte ilk adım, girdi alanının tamamını,  $x_1 < \theta_1$  veya  $x_1 > \theta_1$  olup olmama durumuna göre ikiye böler. Bu ayırım, eğer sorulacak başka sorular varsa, başka alt yaprakların oluşmasına da neden olmuştur. Örneğin,  $x_1 > \theta_1$  bölgesi,  $x_2 > \theta_3$  bölgesi için  $\epsilon$  olarak ayrılan bölge oluşur. Öğrenilen model, sınıflandırma kuralları ve fonksiyonunu içerir. Buna bu sınıflandırıcı da karar ağacı ismi de verilmektedir.



Şekil 4.3. Karar Ağaçları

Sınıflandırmanın durma şartı, gelen her bir eğitim verisi için, daha fazla soru oluşturulamayacak yaprak düğüme gelindiğinde sınıflandırma tamamlanmış olur; Bu oluşturulan sorulara göre, ayrışma grupları arasındaki riski maksimize edecek şekilde tasarlanır ve iyi ayrışmayı bulmak için her soruda bu işlem tekrarlanır; ancak çoğu zaman eğitim verilerini daha küçük düğümlere kadar ayrıştırmak mümkün olur. Bu durumda ya alt dallara bölümlenme belirli bir iterasyondan sonra durdurulur ve kusurlu veri olabileceği kabul edilmiş olur ya da alt kümelerle bölümlenmek için yeni sorular sorularak ağacın aşağıya (yapısına göre yana doğru) dallanması sağlanır.

Test adımında ise, Yeni bir test verisi  $x$  için (eğitim setinde yer almayan veri), kök düğümden başlayarak, bağlantı noktalarında oluşturulmuş sorular sorularak test verisinin hangi bölgeye düştüğü tespit edilir. Yani, eğitim verisinde yer almayan bir veri seti ile öğrenilmiş olan model test edilir ve başarımı ölçülür. Eğer doğruluk, geliştirilen probleme göre kabul edilebilir ölçütte ise model sınıflandırma amacıyla tercih edilir.

Karar Ağaçları, radar sinyallerinin sınıflandırılması, karakter tanıma, uzaktan algılama, medikal teşhis, konuşma tanıma, kredi skorlama gibi birçok alanda başarılı bir şekilde kullanılmıştır [67]. Buna ek olarak, Karar Ağaçları'nın en büyük katkısı karmaşık karar verme süreçlerine anlaşılır ve etkin çözümler sunmasıdır. Diğer birçok sınıflandırma algoritma ve tekniğinin aksine görselleştirilebilmesi sebebiyle anlaşılabilirliği yüksektir.

Karar ağaçları sınıflandırma problemi için yaygın olarak kullanılır. Karar ağaçları algoritmalarının temel olarak adımları aşağıdaki gibidir:

- *Adım (1:)* D öğrenme kümesini oluştur.
- *Adım (2:)* D kümesindeki verileri en iyi ayırıştıran özelliği belirle.
- *Adım (3:)* Seçilen özellik ile ağacın bir düğümünü oluştur. Bu düğümden çocuk düğümleri veya ağacın yapraklarını oluştur. Çocuk düğümler için alt veri kümesinin verilerini sapt.
- *Adım (4:)* Aşağıdaki durumlara göre ağaç oluşturma durma şartını belirle: *a.* Adım (3)'te oluşturulan her alt veri kümesi için; verilerin hepsi aynı sınıfa aitse, verileri bölecek özellik kalmamışsa (ağaç ayırıştırma durma şartları sağlanmışsa) işlemi sonlandır. *b.* Adım (4a)'nın dışında kalan durumlar için Adım (2)'ye git.

Karar ağaçlarında en iyi ayırt edici özelliği bulmak için, bilgi kazancı ölçütü kullanılır. ID3, C4.5, C5 gibi algoritmaların temeli bilgi kazancına dayanır. Bilgi kazancını hesaplamak için entropi kavramından faydalanılır. Bilgi, Shannon'un tanımlamasına göre, Entropi, bir veri seti içerisindeki belirsizliğin veya rastgeleliğin bir ölçütüdür yani belirsizliğin veya beklenmeyen durumun ortaya çıkma olasılığını belirtir.

$\langle p_1, p_2, \dots, p_n \rangle$  olasılık değerleri olmak üzere  $I(P) = - \sum_i^n p_i * \log(p_i)$  entropi formülü 4.13 ve 4.14 ifadelerinde verilmiştir.

$$H(X) = E(I(X)) = \sum_{i=1}^n p(x_i) \log_2 \left( \frac{1}{p(x_i)} \right) \quad (4.13)$$

$$H(X) = E(I(X)) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (4.14)$$

A özelliğinin D veri setindeki, bilgi tanımı (ortalama entropi) aşağıdaki 4.15 formüldeki gibi yapılır:

$$I(D, A) = \sum_i^n \frac{|D_i|}{|D|} Entropy(D_i) \quad (4.15)$$

A özelliğinin D veri setindeki bilgi kazancı ise 4.16 formülündeki gibidir:

$$Gain(D, A) = Entropy(D) - I(D, A) = Entropy(D) - \sum_i^n \frac{|D_i|}{|D|} Entropy(D_i) \quad (4.16)$$

Karar ağacı oluşturmak için geliştirilen birçok algoritma bulunmaktadır. Bu algoritmalar kök düğüm seçme, düğüm ve dallanma koşullarındaki seçimler ile birbirlerinden ayrılırlar. Karar ağacı oluşturma algoritmaları olarak, CHAID (Chi-Squared Automatic Interaction Detector), Exhaustive CHAID, CART (Classification and Regression Tree), ID3, C4.5, MARS (Multivariate Adaptive Regression Splines), QUEST (Quick, Unbiased, Efficient Statistical Tree), C5.0, SLIQ (Supervised Learning in Quest), SPRINT (Scalable Parallelizable Induction of Decision Trees) sıralanabilir.

#### 4.4.1.1.1 CHAID Algoritması

CHAID algoritması, "Otomatik Ki-Kare Etkileşim Belirleyicisi" olarak da isimlendirilebilir. Kaas tarafından 1980 yılında en iyi karar bölmesini hesaplamak için istatistiksel

olarak anlamlı bir farklılığın olmadığı, amaç değişkene uyan çiftlerde kestirim değişkeninin olası kategori çiftini birleştirmesiyle oluşturulmuştur [56]. En uygun bölümleri seçmek için kullanılan teknikler; gini ve entropi ölçütleri, CHAID algoritmasında kullanılmamaktadır. Bunun yerine Ki-Kare (chi-square) testi kullanılmaktadır. En iyi bölmeyi hesaplamak için kestirim değişkenleri amaç değişkenine uyan bir çiftin içinde istatistiksel olarak anlamlı bir fark kalmayınca kadar birleştirilmeye devam edilir. CHAID ile diğer algoritmalar arasındaki en önemli farklardan biri, ID3, C4.5 ve CART gibi algoritmalar ikili ağaçlar üretirken, CHAID çoklu ağaçlar oluşturmaktadır. CHAID tekniği, çoklu ağaç dallanmalarını sağlarken *ki – kare* ölçütünü kullanır ve veri setindeki ilişki ve benzerliklere göre ayrı ayrı sınıflandırmaya, ağacın yapraklarını ikiden fazla bu ilişki düzeylerine göre çoklamaktadır.

CHAID algoritması adımları aşağıdaki gibidir [69]:

- *Adım (1):* Her bir tahmin edici  $X$  için,  $X$ 'in,  $Y$  amaç değişkenine göre en büyük  $p$  değerini bul. (en ağırlığa sahip kategori çifti.) Bu  $p$  değerinin hesabı aşağıdaki koşullara göre belirlenir:
  - a. Eğer  $Y$  sürekli ise F testini kullan.
  - b. Eğer  $Y$  metinsel ise,  $X$ 'in sınıf verilerini satırlarda ve  $Y$ 'nin sınıf verilerini sütunlarda olacak şekilde tablo düzenle. *ki-kare* ya da *olabilirlik oranı* testini kullan.
  - c. Eğer  $Y$  sıralı ise, bir *Y birliktelik modeli* tasarla ve *olabilirlik oranı* testini kullan.
- *Adım (2):* En büyük  $p$  değerine sahip  $X$ 'in sınıf çifti için,  $p$  değerini önceden belirlenmiş alfa değişkeni ( $\alpha$ ) ile kıyasla.
  - a. Eğer  $p$  değeri  $\alpha$ 'dan küçükse *Adım (3)*'e git.
  - b. Eğer  $p$  değeri  $\alpha$ 'dan büyükse bu sınıf çiftini tek bir sınıf altında birleştir.  $X$ 'in yeni sınıf değerler kümesi için *Adım (1)*'e git.
- *Adım (3):*  $X$ 'in ve  $Y$ 'nin sınıf değerler kümesi için uygun Bonferroni çarpanını kullanarak, değiştirilmiş yeni  $p$  değerini hesapla.

- *Adım (4):*  $p$  değerinin önceden tanımlanmış  $\alpha$  değeriyle kıyaslayarak, en küçük değiştirilmiş  $p$  değerine sahip  $X$  tahmin edici değerini seç:
  - a. Eğer  $p$  değeri,  $\alpha$  değerinden küçük veya eşit ise ilgili düğümü  $X$ 'in sınıf değerleri kümesini referans alarak böl.
  - b. Eğer  $p$  değeri,  $\alpha$  değerinden büyük ise düğümü bölme. Bu düğüm yaprak düğümdür. Ağaç büyütme durma kurallarını bozacak durum oluşana kadar devam et.

#### 4.4.1.1.2 CART Algoritması

Karar ağaçlarında en iyi bölmeyi hesaplamak için Sınıflandırma ve Regresyon Ağaçları (CART) tekniği 1980'li yıllarda Freidman, Olshen, Stone ve Breiman tarafından literatürde açıklanmıştır. CART, odaklanılan veri seti üzerinde hiçbir varsayıma ihtiyaç duyulmaması nedeniyle alternatif tekniklerden ayrışır. CART tekniği, kategorik verilere sahip veri setlerinde kullanılabilen parametrik olmayan bir istatistiksel yöntemdir ve bu yöntem sınıflandırma ağaçları olarak adlandırılır. Eğer veri setindeki veriler sürekli değerlere sahipse bu yöntem de "Regresyon Ağaçları" ismini alır. Yapılan çalışmalarda CART tekniği, her aşamada ilgili veri setini kendinden daha küçük ve homojen olan iki alt veri setine ayrıştırarak ikili karar ağaçları oluşturur. En iyi bağımsız değişken safsızlığı (impurity) ve değişim ölçütlerini (Gini indeksi, Twoing ölçütü, En Küçük Kareler Sapması vb.) kullanılır. Burada amaç en iyi amaç-hedef değişken fonksiyonlarına göre en iyi alt veri setlerini oluşturmak ve veri setini sınıflandırmaktır.

#### 4.4.1.2 Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), denetimli sınıflandırma kategorisinde yer alan, istatistiksel öğrenme temelli (Vapnik-Chervonenkis teorisi kast ediliyor.), yapısal risk minimizasyonu prensibine dayanan bir sınıflandırma algoritmasıdır. DVM, boyutsallık laneti probleminde karşı dayanıklıdır. Boyutsallık laneti, sınıflandırma, kümeleme ve öznitelik çıkarımı gibi problemlerde, veri setinde değerlendirmeye katılacak ayırt edici özellik sayısının çok fazla olması durumunda yapılacak sınıflandırmanın veya kümelemenin


isabetsizleşmesi, hatta sınıflandırılma yapılamaması durumudur.

Destek Vektör Makineleri, veri setinin doğrusal olarak ayrıştırılabilme veya ayrıştırılmama durumuna göre ikiye ayrılmaktadır. Bunlar doğrusal veya doğrusal olmayan olarak incelenecektir.

#### 4.4.1.3 Doğrusal Destek Vektör Makineleri

Destek vektör makineleri, ilk olarak iki sınıfı birbirinden ayırmak için doğrusal veri setlerinde sınıflandırılması için tasarlanmış olup daha sonraları genişletilerek doğrusal olmayan veri setleri içinde kullanılabilir hale getirilmiştir. DVM'nin çalışma esası iki sınıfı veya birçok sınıfı içeren sınıfları birbirinden ayırmak için, en uygun karar fonksiyonunun oluşturulması, yani sınıfları birbirinden en iyi ayıran karar düzlemi (hiper-düzlem) bulma problemidir [63]. Karar fonksiyonların, diğer bir adı da destek vektörleridir [56].

DVM, ikili sınıflandırıcı olarak ele alınacak olursa, Şekil 4.4 şeklinde belirtildiği gibi ki sınıfı birbirinden ayıran sonsuz sayıda doğrusal karar düzlemi bulunabilir. Bu karar düzlemlerinin hiçbiri önceden görülmemiş olan test verilerinde iyi sonuçlar ya da iyi bir sınıflandırma, ayrıştırma sağlamayı garantilemez. Sınıflandırıcı görülmemiş test verilerini de sınıflandırmak için bir hiper düzleme karar vermek zorundadır.




Şekil 4.4. Doğrusal Dağılabilen Veri Seti İçin Muhtemel Karar Düzlemleri Dağılımı


En iyi karar düzlemi, marjin değerini maksimize eder. Marjin değeri, iki farklı sınıf verilerinden karar düzlemine en yakın olan iki verinin uzaklık toplamıdır [56]. Şekil 4.6



şeklinde **B1** ve **B2** karar düzlemleri hiç bir sınıflandırıcı hatasına sebep olmadan eğitim verilerini böldüğünü varsayalım. Her bir karar düzlemi **Bi**, iki hiperdüzlem ile ilişkilidir ve bunlar **bi1** ve **bi2** şeklindedir. **bi1** karar düzlemi elde edilirken, **B1** ve **B2** düzlemlerine paralel olarak, en yakın sınıflandırıcıdaki (kare) bir elemana değene kadar kaydırılır. **bi2** karar düzlemi elde edilirken, **B1** ve **B2** düzlemlerine paralel olarak, en yakın bir diğer sınıflandırıcıdaki (üçgen) bir elemana değene kadar kaydırılır. Bu elde edilen **bi1** ve **bi2** arasındaki uzaklık sınıflandırıcının marjini olarak bilinir. Şekil 4.6 şeklinde görüldüğü gibi **B1** karar düzleminin marjini **B2**'den gözle görülebilir şekilde fazladır. Bu örnekte **B1** karar düzlemi maksimum marjine sahip hiper-düzlemi temsil etmektedir. Büyük marjine sahip karar düzlemleri daha iyi sınıflandırma (modeli genelleştirme) eğilimindedir. Şekil 4.6 şeklinde karar düzlemine paralel  $b_{21}$  ve  $b_{22}$  doğruları sınır düzlemlerini ifade eder.



Şekil 4.5. Karar Düzlemleri Marjin Gösterimi



Şekil 4.6. Karar Düzlemleri Marjin Gösterimi

Eğitim verilerine göre karar düzlemi ve bunun sonunda model öğrenildikten sonra her işlenen test verisi için karar düzleminin hangi yarısında kaldığına göre ilgili test verisi sınıflandırılmış olacaktır.

Her bir eğitim verisi  $n$  adet özneliğe sahip  $x_i \in R^n$  vektörü ve örneklerin ait olduğu  $z_i \in \{1, -1\}$  sınıfı ifade eden  $(x_i, z_i)$  ikilisinden oluşmaktadır. Farklı grup sınıf verilerini birbirinden ayıran bir karar düzlemine sahip olduğumuzu varsayılırsa, karar düzlemi üzerinde tanımlanan her bir  $x$  Denklem 4.17 ifadesini sağlamak zorunda olacaktır. Denkleminde  $\omega$  karar düzleminin normalini ifade ederken,  $\omega_0$  karar düzlemi sabiti olarak tanımlanmaktadır.

$$g(x) = \omega^T \cdot x_i + \omega_0 = 0 \quad (4.17)$$

Doğrusal Destek Vektör Makineleri en büyük marjlinli karar düzlemini bulmayı amaçlamaktadır. Tüm eğitim verilerinin Denklem 4.18 ifadesindeki eşitsizlikleri sağladığını varsayalım:

$$\begin{aligned} \omega^T \cdot x_i + \omega_0 &\geq 1 & x_i \in \text{Sınıf 1} & z_i = +1 \\ \omega^T \cdot x_i + \omega_0 &\leq -1 & x_i \in \text{Sınıf 2} & z_i = -1 \end{aligned} \quad (4.18)$$

Denklem 4.18 ifadesindeki eşitsizlikler Denklem 4.19 ifadesindeki gibi sadeleştirilebilir:

$$z_i * (\omega^T \cdot x_i + \omega_0) \geq 1 \quad \forall i \quad (4.19)$$

Herhangi bir eğitim verisi,  $x$  ile sınır düzlemi arasındaki uzaklık 4.20 formülüyle hesaplanır:

$$d = \frac{|\omega^T \cdot x + \omega_0|}{\|\omega\|} \quad (4.20)$$

Sınır düzlemine en yakın  $x$  verisi  $|\omega^T \cdot x + \omega_0| = 1$  eşitliğini sağlarken  $x_i$  verisiyle karar düzlemi arasında  $1/\|\omega\|$  uzaklığında mesafe bulunmaktadır. İki sınır düzlemi arasında kalan mesafe marjin tanımını vereceğinden,  $2/\|\omega\|$  marjin uzaklığı olarak tanımlanacaktır. Marjini maksimum veren karar düzlemi için minimum  $\frac{1}{2}\|\omega\|^2$  değeri, 4.19 denklemini sağlamalıdır.

En iyi karar düzlemi probleminin çözümü için Lagrange teoreminden faydalanılır. Lagrange teoremi, "G sonlu bir grup ve  $H \leq G$  olsun. Bu durumda H alt grubunun mertebesini G grubunun mertebesi böler" literatürde şeklinde tanımlanır ve sayılar teorisi ve grup teorisinin altında incelenir. DVM en iyi karar düzlemi probleminde ise, bir fonksiyonun minimum veya maksimum değerini bulmak için problemi ikili probleme dönüştürülerek analitik olarak çözüme ulaşılmasını tanımlamaktadır. Bu optimizasyon problemi Denklem 4.21'da belirtildiği gibi tanımlanır [71].

$$\begin{aligned} & \min_{\omega} f(\omega) \\ & \text{koşulu altında } g_i(\omega) \leq 0 \quad , i = 1, \dots, k \\ & h_i(\omega) = 0 \quad , i = 1, \dots, l \\ & L(\omega, \alpha, \beta) = f(\omega) + \sum_{i=1}^k \alpha_i g_i(\omega) + \sum_{i=1}^l \beta_i h_i(\omega) \end{aligned} \quad (4.21)$$

Maksimum marjlinli karar düzlemi bulma problemi ise Lagrange metodu ile 4.22 formül-

lyle belirtilebilir.

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega\|^2 \\ \text{k.a.} \quad & z_i(\omega^T \cdot x_i + \omega_0) \geq 1 \quad \forall i \\ L(\omega, \omega_0, \alpha) = & \frac{1}{2} \|\omega\|^2 - \sum_i^n \alpha_i \cdot [z_i(\omega^T \cdot x_i + \omega_0) - 1] \end{aligned} \quad (4.22)$$

Tanımlanan  $L(\omega)$  fonksiyonu  $\omega$  ve  $\omega_0$ 'a gre minimize edilir. Fonksiyonda yer alan tm  $\alpha_i$  deęeri  $\alpha_i \geq 0$  koşulunu saęlamaktadır. Bu optimizasyon probleminin çzm, en iyi karar dzlemini belirleyecektir. 4.23 denkleminde belirtildięi gibi Lagrange fonksiyonu  $\omega$  ve  $\omega_0$ 'a gre kısmi trevleri alınarak sfıra eőitlenir.

$$\begin{aligned} \frac{\partial L_p(\omega, \beta, \alpha)}{\partial \omega} = 0 \quad \Rightarrow \quad \omega - \sum_i^n z_i \alpha_i x_i = 0 \quad \Rightarrow \quad \omega = \sum_i^n z_i \alpha_i x_i \\ \frac{\partial L_p(\omega, \beta, \alpha)}{\partial \omega_0} = 0 \quad \Rightarrow \quad \sum_i^n z_i \alpha_i = 0 \end{aligned} \quad (4.23)$$

Eőitlikler Lagrange fonksiyonuna (4.22) yazılırsa, 4.24 denkleminde verilen optimizasyon problemi elde edilir [72]:

$$L(\omega, \omega_0, \alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n z_i z_j \alpha_i \alpha_j (x_i)^T x_j \quad (4.24)$$


Maksimum marjlinli karar dzlemi 4.25 denklemindeki gibi ifade edilirken karar dzlemi znitelik vektrnn i arpımları Őeklinde yazılabilmektedir.

$$\begin{aligned} g(x) = \sum_i^n (\alpha_i \cdot z_i \cdot x_i)^T \cdot x_i + \omega_0 \\ \text{k.a.} \quad \sum_i^n \alpha_i z_i = 0 \quad \text{ve} \quad \forall \alpha_i \end{aligned} \quad (4.25)$$

#### 4.4.1.4 Doęrusal Olmayan Destek Vektr Makineleri

İkili Destek Vektr Makineleri iin geerli olan doęrusal dzlem ve marjın kavramları geliőtirilerek, birok sınıf ieren veri setleri iin bulunacak olan karar dzlemi doęrusal olmayan fonksiyonlar ile ifade edilir. Doęrusal olmayan bir veri setinde, DVM doęrusal bir hiper-dzlem oluőturamaz. Bu nedenle ekirdek numarası (kernel trick) olarak adlandırılan yntemler kullanılır. Eęitim veri setinin doęrusal bir dzlem ile ayrıőtırlamadıęı

durumlarda, Şekil 4.7 şeklinde belirtildiği gibi genel mantık olarak DVM bu veri setinde yer alan verileri daha yüksek bir boyutlu uzaya dönüştürerek doğrusal ayrışmaya izin verecek hale getirir [72].



Şekil 4.7. Doğrusal olmayan örnek uzayının doğrusal hale getirilmesi

Doğrusal olarak ayrışmayan veri seti uzayı,  $\phi$  olarak tanımlanan bir dönüşüm fonksiyonu (mapping) ile doğrusal ayrışmanın olası olduğu bir başka T uzayına dönüştürdüğümüzü varsayalım.

Tanımlanan bu T uzayında karar düzlemi bulmak için; karar düzleminin normali  $\omega$  Denklem 4.25 ifadesinde olduğu gibi giriş vektörlerinin iç çarpımı olarak tanımlandığından T özellik uzayında bu iç çarpımlar 4.26 denklemindeki gibidir [72]:

$$K(x, x_i) = \phi(x) \cdot \phi(x_i) \quad (4.26)$$

Denklemden K çekirdek fonksiyonunu tanımlarken,  $x_i$  destek vektörlerini belirtir. Denklemden  $x_i$  destek vektörlerini tanımlarken, K çekirdek fonksiyonu olarak çekirdek fonksiyonu, özellik uzayında verilerin koordinatlarının tek tek hesaplanmasına gerek kalmadan direkt olarak ihtiyacımız olan verilerin iç çarpımlarını hesaplayarak yüksek boyutlu

uzayda rahatça çalışılmasına olanak tanır. Bu iç çarpım Denklem 4.25 içerisine yazılırsa ayırıcı düzlem fonksiyonu Denklem 4.27 ifadesindeki gibi ifade edilir.

$$g(x) = \sum_i^n \alpha_i z_i \Phi(x) \Phi(x_i) + \omega_0 = \sum_{i=1}^n \alpha_i z_i K(x, x_i) + \omega_0 \quad (4.27)$$

Literatürde en çok kullanılan çekirdek yöntemleri: Polinom Çekirdek, Sigmoid Çekirdek ve Gaussian RBF Çekirdek fonksiyonları olarak sayılabilir.

- Polinom Çekirdek Fonksiyonu: (Kubik p=3, Quadratic p=2)

$$K_{POL}(x, x_i) = (\langle x, x_i \rangle + 1)^p \quad (4.28)$$

- Sigmoid Çekirdek Fonksiyonu:

$$K_{SIG}(x, x_i) = \tanh(\langle x, x_i \rangle + 1) \quad (4.29)$$

- Gaussian RBF Çekirdek Fonksiyonu


$$K_{RBF}(x, x') = \exp[-\gamma \|x - x'\|^2] \quad (4.30)$$

#### 4.4.1.5 K-En Yakın Komşuluğu

K-En Yakın Komşuluğu metodu ilk olarak 1950'lerin başlarında duyurulmuştur. Bu yöntem bilgisayarlarda işlem gücünün 1960'larda artmasıyla birlikte popülerlik kazanmaya başladı. O zamandan beri veri madenciliği ve desen tanımda yaygın olarak kullanılmaktadır. En yakın komşuluk esasına dayanan sınıflandırıcı analogi yoluyla öğrenmeye dayanır yani karşılaştırmalı olarak eğitim ve test sınıflarının benzerliğini ele alır. Eğitim veri setinde yer alan eğitim değişken grupları n öznitelikleriyle temsil edilir. Her değişken grubu n boyut bir alanda bir noktayı temsil eder. Bu şekilde, tüm eğitim grup değişkenleri n boyutlu bir desen alanında saklanır. Bilinmeyen bir grup değişkeni verildiğinde bir K-En Yakın Komşuluğu sınıflandırıcı, bilinmeyen grup değişkenine en yakın k eğitim değişkenleri için desen boşluğunu araştırır. Bu k eğitim grup değişkenleri, bilinmeyen grup değişkenine ait "en yakın komşular" olarak tanımlanır. Yakınlık ve en yakınlık deyimleri uzaklık metriklerine göre tanımlanır. Bu uzaklık metriklerine, 4.2.3 bölümünde detaylıca yer verilmiştir. Şekil 4.8 iki boyutlu bir örnek uzayında bilinmeyen (test) grup değişkeni

$x_1$  için,  $c_i$  tarafından hangi sınıfa ait olacağına karar verme işlemini göstermektedir.  $x_1$  test grup değişkeninin benzerliği,  $k$  tane komşu eğitim grup değişkenine olan uzaklığına göre belirlenir.  $x_1$  test grup değişkeninin sınıf etiketi,  $k$  en yakın komşunun sınıf etiketlerinin çoğunluğuna göre belirlenir.

K-En Yakın Komşuluğu metodunun performansı  $k$  komşuluk sayısına ve seçilen uzaklık metriğine bağlıdır. Öklid uzaklığı en yaygın olarak kullanılan uzaklık metriğidir; ancak koordinat eksenindeki dağılımlar karşılaştırılabilir olmayan bir eğitim seti olabilir. Bu durumda Öklid uzaklığının bir ön işlemi olarak dağılım matrisini normalize eden ve standartlaştırmak için Mahalanobis metriği de yaygın olarak kullanılır. Komşuluk sayısını kontrol eden  $k$  değişkeni de sınıflandırma performansında önemli bir etkidir [70]. En iyi  $k$  değeri veri setine göre değişiklik göstermektedir. Gürültülü verilerin, veri seti üzerindeki etkisini azaltmak için yaygın olarak  $k$  değişkeni büyük seçilmektedir ve bu sınıflar arasındaki belirginliğin azalmasına neden olmaktadır. Şekil 4.8 şeklinde verildiği gibi dağılımda bilinmeyen bir  $x_1$  test grup değişkeni için  $k=3$  ve  $k=6$  seçimi ile farklı sınıf etiketine ataması sağlanabilir. Bilinmeyen bir grup değişkenini, en yakın komşusunun ait olduğu sınıfa ait etikete göre sınıflandırmak için  $k=1$  alınırken,  $k$  değişkeni tüm örnekleri kapsayacak şekilde (veri setindeki sınıf etiketi sayısı kadar) seçilirse, sınıf etiketi çoğunluk sınıfına göre seçilecektir.



Şekil 4.8. K-En Yakın Komşu - Bilinmeyen bir değişken grubunun ataması

#### 4.4.1.6 Topluluk Öğrenmesi Metotları

Çalışmamız kapsamında incelenen sınıflandırıcılardan K-En Yakın Komşuluğu dışında kalan sınıflandırıcılarda genel yaklaşım eğitim veri seti kullanılarak eğitilmiş bir sınıflandırıcıyla bilinmeyen bir verinin sınıf etiketini belirlemeye yöneliktir. Topluluk öğrenmesi metotlarında ise yaklaşım birden fazla sınıflandırıcıyla birlikte etiketi bilinmeyen verinin sınıfına bulmaya yöneliktir. Topluluk öğrenmesi yöntemleri, "temel sınıflandırıcılar" ismi verilen sınıflandırıcı toplulukları oluşturur. Bilinmeyen verinin etiketi tahmin edilirken, Bu temel sınıflandırıcılara bu verinin etiketi sorulur ve daha sonra oylama yapılarak en çok oy alan sınıfın etiketi bilinmeyen veriye atanır. Bu şekilde her biri farklı avantaj ve dezavantaj içeren sınıflandırıcıların, yanlış sınıflandırma yapma olasılıkları düşürülmüş ve genel olarak başarımlarını artırımı sağlama amacı bulunmaktadır. Bu Topluluk Öğrenmesi Yöntemleri'ni bir örnekle açıklamak gerekirse; 0.35  $\epsilon$  hata oranına sahip 25 ikili(binary) sınıflandırıcımız olduğunu varsayalım. Topluluk öğrenmesi temel sınıflandırıcıları, bilinmeyen bir veriye etiket vermek için sonuçlarını dönecekler ve verilen etiket sonuçları arasında oylama yapılır. Eğer temel sınıflandırıcılar özdeş ise sınıflandırma sonucu yanlış olacaktır. Bu şekilde hata oranı 0.35 olarak kalmaya devam edecektir; ancak temel sınıflandırıcılar birbirinden farklı ise (hata oranları veya yöntemlerin farklı olması), bu sınıflandırıcıların hatalı sonuç üretmesi için yarısından fazlasının hatalı olarak sonucu vermesi gerekmektedir.

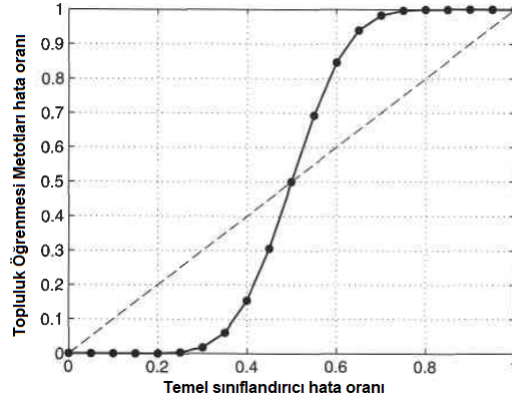
Bu durumda hata oranı 4.31 ifadesindeki gibi hesaplanır.

$$e_{ensemble} = \sum_{i=13}^{25} \binom{25}{i} \epsilon^i (1 - \epsilon)^{25-i} = 0.06 \quad (4.31)$$

4.31 formülünde görüldüğü gibi hata oranı oldukça düşmüştür. ( $0.06 \leq 0.35$ ) Şekil Şekil 4.9 25 sınıflandırıcının 4 temel sınıflandırıcıya göre hata oranları grafiğini göstermektedir. Kesikli olarak gösterilen doğru, temel sınıflandırıcıların özdeş olduğu durumu göstermektedir; kesikli olmayan ve koyu renkle ifade edilen doğru ise temel sınıflandırıcıların birbirinden farklı (bağımsız) olduğu durumu belirtmektedir. Grafik incelendiğinde temel sınıflandırıcıların hatasının 0.5'den küçük olduğu durumlarda Topluluk Öğrenmesi



Metodu'nun hata oranı düşük olmaktadır; ancak temel sınıflandırıcılar 0.5 hata oranından daha fazla hata üretmeye başladığında Topluluk Öğrenmesi Metodu 0.5'den daha yüksek bir hata oranı üretmeye başlamıştır. Bu durumda Topluluk Öğrenmesi Metotları, temel sınıflandırıcı seçimine ve temel sınıflandırıcıların birbirinden bağımsız olması durumunda tek sınıflandırıcı çözümlere göre daha başarılıdır [56].



Şekil 4.9. Topluluk Öğrenmesi Metotları'nın hata oranının Temel Sınıflandırıcı hata oranına göre değişimi


#### 4.4.2

MLP Sınıflandırıcısı MLP (Multilayer Perceptron) sınıflandırıcı "Yapay Sinir Ağları" olarak da bilinir. Yapay Sinir Ağları'nın dayandırıldığı ilk makele 1940 yılının başında McCulloch ve Pitts tarafından yayımlandı. 1954 yıllarında Farley ve Clark bir yapay sinir ağı tanımı ve uyarı-tepki mekanizmalarını modellemiştir. 1985 yılı yapay sinir ağlarının oldukça popülerleştiği ve araştırmaların başladığı yıl olmuştur. Yapay sinir ağları insan beyninin yapısından esinlenilerek tasarlanılmış, bağlantı noktalarına ağırlıklar vererek birbirine bağlayan ve her biri kendi bireysel belleğine sahip işlemcilerden oluşan paralel veya dağıtık bilgi işleme yapıları; veya biyolojik sinir ağlarının taklit eden bilgisayar programcılarıdır.

##### 4.4.2.1 Tek Girişli Nöron

Tek Girişli bir nöron girdi, çıktı ve transfer-aktivasyon fonksiyonundan oluşur. Temel olarak girdi olarak gelen değer, belli bir değer ile çarpılıp (sinapsislerin değer farklılaşması

için kullanılır) ve sabit bir değer ile toplanıp daha sonra seçilmiş olan transfer-aktivasyon fonksiyonuna iletilir. Fonksiyonda yapılan işlemler sonrası çıktı oluşturulur. Bu basit dönüşüm ve fonksiyon işlemi ile insan beyninde yer alan bir nöron modellenmiş olur ve birçok nöron ile verilerin sınıflandırma problemleri çözülmeye çalışılır. Girdi değeri "p", sinapsis ağırlıklarının ayarlanması için "w" değeri kullanılmak üzere, nöronun gövdesini toplam fonksiyonu ve aktivasyonu fonksiyonu temsil eder ve "a" değeri bu nöron için çıktı değerini belirler ve başka bir nörona da girdi oluşturabilir. Bu belirtilen isimlendirme ile gösterilen tek girişli nöron yapısına Şekil 4.10 şeklinden erişilebilir.



Şekil 4.10. Tek Girişli Nöron

Transfer-aktivasyon fonksiyonları nöronun yapacağı işe göre farklılar gösterebilir, bu matematiksel fonksiyon doğrusal olabileceği gibi doğrusal olmayan bir fonksiyondan da oluşabilir. En çok kullanılan transfer-aktivasyon fonksiyonları aşağıdaki gibidir:

- **Hard Limit Transfer Fonksiyonu** : İkili bir sınıflandırıcı gibi düşünülebilir. Belli bir değerden büyük olan girdi değerine karşılık "1" değerini üretirken, belirlenen değerden küçük bir girdi değeri için "0" üretir.
- **Doğrusal Transfer Fonksiyonu** : Çıkış değeri giriş değerine doğrusal olarak bağlı olan fonksiyon türüdür. Örneğin,  $f(x) = ax + b$  şeklinde olan bir fonksiyon için girdi değeri bir "a" değeri ile çarpıldıktan sonra "b" değeri ile toplanır ve çıktı değeri oluşur.
- **Sigmoid Fonksiyonu** : Bir girdi değerini "0" veya "1" olarak çıktı üreten logaritmik bir fonksiyondur. Girdi değerleri artı sonsuz veya eksi sonsuz arasında olabilir.


Sıklıkla kullanılan transfer fonksiyonlarına, girdi ve çıktı sınır değerlerine, sembol değerlerine Çizelge 4.1 tablosundan erişilebilir.

Transfer Fonksiyonu	Girdi-Çıktı	Sembol
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$	$\square$
Simetrik Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$	$\boxplus$
Doğrusal	$a = n$	$\boxtimes$
Satüre Doğrusal	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$	$\boxdot$
Simetrik Satüre Doğrusal	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$	$\boxminus$
Sigmoid	$a = \frac{1}{1 + e^{-n}}$	$\boxcirc$
Hiperbolik Tanjant	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	$\boxdot$
Positif Doğrusal	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$	$\boxtimes$

Çizelge 4.1. Transfer Fonksiyon Listesi ve Gösterimi

#### 4.4.2.2 Çoklu Giriş Nöronu


Bir nörona birden fazla girdi değerinin olduğu nöron şeklidir. Girdi değerleri "p" ile gösterildiğinde ve sinapsis ağırlıkları da w ile gösterildiğinde bir çoklu giriş nöronu Şekil 4.11 şeklinde gösterildiği gibidir.



Şekil 4.11. Çok Girişli Nöron

#### 4.4.2.3 Tek Katmanlı Ağ Mimarisi

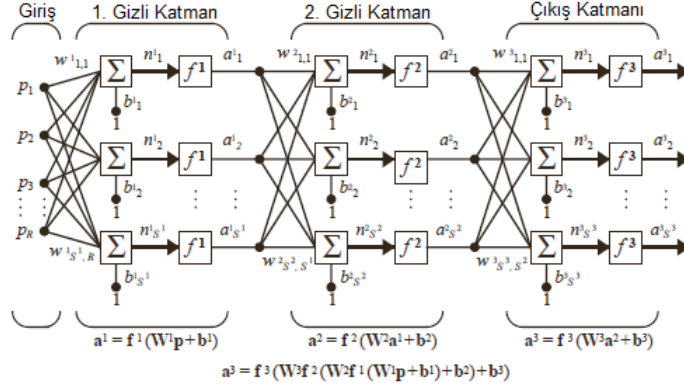
Tek katmanlı ağ mimarisinde girdi değerleri ( $p$ ), sinapsis ağırlık değerleriyle çarpılarak ( $w$ ) nöron gövdesine giriş sağlanır ve her biri ayrı çıktı değerleri oluşturur. Tek katmanlı ağ mimarisine Şekil 4.12 şeklinden erişilebilir.



Şekil 4.12. Tek Katmanlı Ağ

#### 4.4.2.4 Çok Katmanlı Ağ Mimarisi

Tek katmanlı ağ mimarisinde birçok veri uzayını eğitmek neredeyse imkansızdır ya da tek katmanlı bir nöral ağın başarımı çok düşük olmaktadır. Bu yüzden çok katmanlı ağ mimarileri ortaya atılmıştır. Sinapsislerin ağırlıkları ( $w$ ), transfer fonksiyonu  $n$  tane giriş vektörü ve çıktı değerleri ise " $a$ " ile sembolize etmek üzere Şekil 4.13 şeklinde belirtilmiştir. Bu çok katmanlı ağ mimarilerinde her bir katman birbirinden farklı bir transfer fonksiyonuna sahip olabilir. Örneğin ilk katman Sigmoid Fonksiyon kullanırken ikinci katman Doğrusal Transfer Fonksiyonu olabilir.



Şekil 4.13. Çok Katmanlı Ağ

Çok katmanlı bir nöral mimarinin başarımını arttırmak mümkündür. Öncelikle ağın girdi sayısını öznelik uzayı sayısı kadar yapmak doğru olacaktır. Ek olarak, ağ çıkış sayısı da veri setinde yer alan sınıf sayısı kadar nöron içermelidir. Son olarak, ağın en son çıkış değerinde doğru veya yanlış gibi bir sonuç isteniyorsa ikili sonuç üreten "Sigmoid" veya "Hard Limit" benzeri transfer fonksiyonuna benzeyen bir aktivasyon-transfer fonksiyonu seçilmelidir. Çok katmanlı ağ mimarisinde yer alması gereken gizli katman sayısını doğrudan belirlemek çok güçtür. Bu belirleme veri setine, veri seti büyüklüğü gibi birçok değişkene bağlıdır. Bu yüzden gizli katman sayısı belirlemede sınıflandırıcıların değerlendirme metrikleri kullanılarak ideal sayı bulunabilir; ancak genel olarak giriş katmanı, gizli katman ve çıkış katmanı içeren Çok Katmanlı Ağ mimarisine sahip bir MLP sınıflandırıcı bir çok problemi başarılı olarak çözebilmektedir. Bu yapılarda ayrıca sınıflandırıcı başarımını arttırmak için "Geri Besleme" tekniği kullanılır ve sınıflandırıcıdaki hataları minimuma düşürme amacındadır.

## 5. OMUZ FİZYOTERAPİ HAREKETLERİNİN SINIFLANDIRILMASI

Tezimiz kapsamında oluşturulmuş Hacettepe-Omuz veri setlerinde yer alan RGB, derinlik ve konum verileri, 30 kare(frame)/saniye görüntü ve konum yakalama özelliği olan RGB-D kamera ile oluşturulmuştur. Bu nedenle, kayıt edilmiş bir omuz fizyoterapi hareketi, birbirine benzer birçok kareden oluşmaktadır. Bu benzer özellikli kareler hiçbir ön işlem yapılmadan veri madenciliği algoritmaları ile işlenilmeye başlanıldığında; veri madenciliği algoritmalarının verimi, öğrenme ve test işleme sürelerinde uzamalara neden olmakta, hatta bazı veri madenciliği tekniklerinde öznitelik uzayının büyüklüğü nedeniyle sonuç alınamamıştır. Bu nedenle öznitelik uzayının büyüklüğünü düşürmek için sorun kümeleme problemi olarak ele alınmıştır ve hareketi en iyi özetleyen frame'ler bulunmaya çalışılmıştır. Bu ön işleme sürecinden sonra veri madenciliği algoritmalarından K-En Yakın Komşuluğu, Destek Vektör Makineleri, Kalibre Edilmiş Destek Vektör Makineleri, Karar Ağaçları, MLP sınıflandırıcı ve Topluluk Öğrenmesi Yöntemleri üzerinde öğrenme ve test süreçleri sadece konum veri seti üzerinde uygulanmıştır ve Hacettepe-Omuz veri setlerini en iyi modelleyen yöntem tespit edilip model ViTES uygulamasında kullanılması amaçlanmıştır.

### 5.1 Fizyoterapi Egzersiz Hareketlerinin Özetlenmesi

Çalışma kapsamında oluşturulan Hacettepe-Omuz veri setlerinde yer omuz fizyoterapi hareketleri ortalama olarak 5-30 saniye civarında, ortalama 300 kare içermektedir. Omuz fizyoterapi hareketleri yapan kişilerin, hareketleri (aynı hareketi bile) farklı sürelerde tamamlamalarından dolayı kare sayılarında değişkenlikler oluşmaktadır. Ek olarak, bir hareket için 30 frame/saniyede kayıt yapıldığı için birbirine benzer özellikte birçok konum verisi bulunmaktadır. Bu şekilde problem, hareketi en iyi temsil eden frame'leri tespit etme problemine dönüşmüştür.

Öznitelik uzayı tanımlanırken, vücudu temsil etmek için 20 adet eklem konumu (bu eklemlerle ilgili bilgiye 3.2.2 bölümünden erişilebilir), uzaysal eklem konum verileri (X, Y, Z) ve kare sayısı kullanılır. Burada eklem konumları (20 adet) ve uzaysal konum verileri (3 adet) sabitken kare sayısı değişkendir. Değişken olan kare (frame) sayısını belirlemek için En Düşük Kare Sayı'sında Kesme, Rastsal Yaklaşım ve Kare (Frame) Özetleme

Tekniđi kullanılmıřtır.

### **5.1.1 En Düşük Kare Sayısı'nda Kesme**

Öznitelik uzayının boyutunu belirlerken en önemli etken deđişken olan kare sayısını sabitleme gerekliliđidir. Bunun için tüm kareler incelenir ve en düşük kareye sahip olan hareket esas alınacak şekilde kare sayısı belirlenir. Örneđin; veri setimiz 300, 600, 1200 kare içeren üç hareketten oluşuyor olsun. Bu yöntemle göre tüm hareketlerin ilk 300 frame'i alınarak kare sayısının sabitlenmesi yoluna gidilir. Sonuç olarak her hareketin ilk 300 frame'i alınmış olacaktır(bu şekilde öznitelik uzayının boyutu da 3x20x350 olacak şekilde belirlemiş oluruz). Bu yöntemin en büyük eksikliđi hareketlerin büyük bölümünün alınamaması ve hareketlerin iyi bir şekilde temsil edilememesidir. Örneđimize bakıldığında 1200 kareden oluşan hareket sadece 1/4'ü ile temsil edilmeye çalışılmıştır. Bu yüzden veri madenciliđi teknikleri uygulanması sonucunda birçok hareketin birbirine karıştığı, eğitim ve test veri setlerinde başarımların düşük olduđu gözlemlenmiştir.

### **5.1.2 Rastsal Yaklaşım**

Rastsal yaklaşım, önceden belirlenmiş sabit bir kare sayısına göre zamana göre akan hareketten karelerin rastsal seçilmesi esasına dayanır. Örneđin; 500 kare içeren bir hareketi en iyi temsil eden hareketler belirlenmek istenirken, sabit bir kare sayısı belirlenir. Bu örnekte sabit kare sayısı 5 olsun (Bu şekilde öznitelik uzayının boyutunu da 3x20x5 şeklinde belirlemiş oluruz.) 500 kareden 5 kare elde etmek için artış indisimiz 100 olacaktır ve 0, 100, 200, 300, 400 numaralı frame'ler hareketi temsil etmek için seçilecektir. Bu yaklaşım, ilk yaklaşıma göre çok daha iyi sonuçlar vermektedir. Hareketin zaman ekseninde birbirinden farklı kareler ile temsil edilmesi sağlanmıştır; ancak en iyi temsil eden kareleri bulmak için yeterli olmamaktadır.


### **5.1.3 Hareket Özetleme Tekniđi**

Birçok kareden oluşan hareketi en iyi temsil eden kareleri ve optimal kare sayısını bulmak için problemi kümeleme problemi olarak ele almak doğru olacaktır. Kümeleme problemi çözümü için literatürde yaygın olarak kullanılan K-Means ve K-Metodoid algoritmaları kullanılmıştır. (Bu algoritmalar hakkında detaylı bilgiye 4.2.1 ve 4.2.2 bölüm-

lerinden erişilebilir.) Birçok kareden oluşan hareket önceden belirlenmiş sabit sayıdaki kare ile temsil etmek amaçlanır. Öncelikle bir sabit kare sayısı belirlenir, bu belirlenmiş sabit sayı aslında kümeleme algoritmalarının ilgili veriyi kaç gruba ayıracağını belirtir. Kümeleme algoritmalarının belirtilen sayı kadar gruplaması sonucu, her grubu en iyi temsil eden kare uzaklık kriterlerine göre uygun olacak şekilde grubun uzaysal olarak orta noktasına denk gelecek şekilde seçilir. Böylece önceden belirlenmiş kare sayısı kadar kare hareketi temsil etmek için elde edilmiş olur.

Bir örnek ile açıklayalım: 1500 kare içeren bir hareketi, 5 adet kare ile temsil etmek istediğimizi varsayalım. Bu örnek Şekil 5.1 figürüyle desteklenmiştir. Kümeleme algoritması kullanarak (bu örnekte K-Means algoritması), birbirine benzer kareler bir grupta yer alacak şekilde 5 grup elde edilir. Bu gruplardan grubu en iyi temsil eden kare, uzaklık metriklerine göre grubun en ortasında kalacak olan uzaklık tanımlarını içeren frame'e göre seçilir. Bu işlemlerin sonucunda, birbirine çok benzer veriler içeren 1500 frame'lik hareket 5 kare ile temsil edilmiş olur. Bu 5 kareye hareketi en iyi temsil eden kareler ismi verilir. Çalışma kapsamında sabit kare sayısının nasıl seçileceğine dair Hacettepe-Omuz veri setleri üzerinde çalışmalar yapılmıştır. Bu çalışmalara 7 bölümünden erişilebilir. Bu şekilde öznitelik uzayı da  $3 \times 20 \times 5$  seviyesine düşürülür.





Şekil 5.1. Hareket Özetleme Yöntemi

## 5.2 Fizyoterapi Egzersiz Hareketlerinin Sınıflandırılması

Fizyoterapi egzersiz hareketlerinin sınıflandırılmasında "Python" dilinde yer alan "sklearn" kütüphanesi kullanılmıştır. Bu bölümde verilen sonuçlarda, "Veri Setleri" 3 bölümünde açıklanan veri setlerinden Hacettepe-Omuz 1, Hacettepe-Omuz 2, Hacettepe-Omuz 3 ve Hacettepe-Omuz veri setleri eğitim için; Hacettepe-Omuz 5 veri seti ise test amacıyla kullanılmıştır. Veri setlerinde ilgili hareketlerde toplamda 739 veri bulunmaktadır, 669 egzersiz hareketi eğitim için geriye kalan 70 harekette test amacıyla kullanılmıştır. Eğitim / Test veri setlerinin ayrılışımı yaklaşık olarak %90 - %10 olarak belirlenmiştir. Destek Vektör Makineleri (DVM), Kalibre Edilmiş Destek Vektör Makineleri, Karar Ağaçları, K-En Yakın Komşu (KNN) ve Yapay Sinir Ağları (YSA veya MLP) sınıflandırma yöntemleri ve bunların alt türevleri bu bölümde açıklanacaktır. Sınıflandırıcı doğruluk ölçülmesi için, "Hassasiyet - Duyarlılık ve f-1 Değeri" sonuçları verilmiş ve egzersiz

hareketlerinin doğruluklarını gözlemleyebilmek için hata matrisleri verilmiştir.

### 5.2.1 Destek Vektör Makineleri

Destek Vektör Makineleri 4.4.1.2 bölümünde kuramsal olarak açıklanmıştır. DVM, sklearn Python kütüphanesi üzerinden 5.1 kod parçacığı ile kullanılmıştır.

```
from sklearn.svm import LinearSVC

model1 = SVC(kernel="linear", C=1, probability=True)
```

Listing 5.1. DVM sklearn Python Kod Parçacığı

DVM sınıflandırıcısının test verisi karşısındaki (eğitim veri setinde yer almayan) başarıyı %98,57 olmuştur. Sınıflandırıcının başarılarını değerlendirmek için kullanılan "Hassasiyet - Duyarlılık - f1 Değeri" Çizelge 5.1 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen başarımları Çizelge 5.2 tablosuyla verilmiştir.

Hareket	Hassasiyet (precision)	Duyarlılık (recall)	f1-Değeri	Destek (Support)
1	1.00	1.00	1.00	10
2	1.00	1.00	1.00	10
3	1.00	0.90	0.95	10
4	1.00	1.00	1.00	10
5	0.91	1.00	0.95	10
6	1.00	1.00	1.00	10
7	1.00	1.00	1.00	10
<b>Doğruluk:</b>			0.99	70
<b>Makro Ortalama:</b>	0.99	0.99	0.99	70
<b>Mikro Ortalama:</b>	0.99	0.99	0.99	70

Çizelge 5.1. Destek Vektör Makineleri - Hassasiyet - Duyarlılık - Destek Sonuçları, K=10

12	100	0	0	0	0	0	0
3	0	100	0	0	0	0	0
4	0	0	90	0	10	0	0
5	0	0	0	100	0	0	0
6	0	0	0	0	100	0	0
8	0	0	0	0	0	100	0
9	0	0	0	0	0	0	100
	12	3	4	5	6	8	9

Predicted Label

Çizelge 5.2. Destek Vektör Makineleri Sınıflandırıcı Hata Matrisi, K=10

### 5.2.2 Kalibre Edilmiş Destek Vektör Makineleri

Kalibre Edilmiş DVM sınıflandırıcı da DVM'in bir türü olup Python sklearn kütüphanesi üzerinden erilmiştir ve bu dildeki 5.2 kod parçacığı ile kullanılmıştır.

---

```

from sklearn.calibration import CalibratedClassifierCV
from sklearn.svm import LinearSVC

model2 = CalibratedClassifierCV(
    base_estimator=LinearSVC(random_state=0, tol=1e-5, max_iter=10000000,
        penalty='l2', dual=False), cv=20)

```

---

Listing 5.2. Kalibre Edilmiş DVM sklearn Python Kod Parçacığı

Kalibre Edilmiş DVM sınıflandırıcısının test verisi karşısındaki (eğitim veri setinde yer almayan) başarımı %97,14 olmuştur. Sınıflandırıcının başarımını değerlendirmek için kullanılan "Hassasiyet - Duyarlılık - f-1 Değeri" Çizelge 5.3 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen başarımları Çizelge 5.4 tablosuyla verilmiştir.

Hareket	Hassasiyet (precision)	Duyarlılık (recall)	f1-Değeri	Destek (Support)
12	1.00	1.00	1.00	10
3	0.91	1.00	0.95	10
4	0.90	0.90	0.90	10
5	1.00	1.00	1.00	10
6	1.00	0.90	0.95	10
8	1.00	1.00	1.00	10
9	1.00	1.00	1.00	10
Doğruluk:			0.97	70
Makro Ortalama:	0.97	0.97	0.97	70
Mikro Ortalama:	0.97	0.97	0.97	70

Çizelge 5.3. Kalibre Edilmiş SVM Sınıflandırıcı - Hassasiyet - Duyarlılık - Destek Sonuçları, K=10

12	100	0	0	0	0	0	0
3	0	100	0	0	0	0	0
4	0	10	90	0	0	0	0
5	0	0	0	100	0	0	0
6	0	0	10	0	90	0	0
8	0	0	0	0	0	100	0
9	0	0	0	0	0	0	100
	12	3	4	5	6	8	9

Predicted Label

Çizelge 5.4. Kalibre Edilmiş Destek Vektör Makineleri Sınıflandırıcı Hata Matrisi, K=10

Karar Ağaçları 4.4.1.1 bölümünde kuramsal olarak açıklanmıştır. DVM, sklearn Python kütüphanesi üzerinden 5.3 kod parçacığı ile kullanılmıştır.

### 5.2.3 Karar Ağaçları

```
from sklearn.tree import DecisionTreeClassifier

model3 = DecisionTreeClassifier(max_depth=50)
```

Listing 5.3. Karar Ağaçları sklearn Python Kod Parçacığı

Karar Ağaçları Sınıflandırıcısı'nın test verisi karşısındaki (eğitim veri setinde yer almayan) başarıımı %77,14 olmuştur. Sınıflandırıcının başarımasını değerlendirmek için kulla-

nılan "Hassasiyet - Duyarlılık - f-1 Değeri" Çizelge 5.5 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen başarımları Çizelge 5.6 tablosuyla verilmiştir.

Hareket	Hassasiyet (precision)	Duyarlılık (recall)	f1-Değeri	Destek (Support)
12	0.67	1.00	1.00	10
3	0.89	0.80	0.84	10
4	0.58	0.70	0.64	10
5	0.64	0.70	0.67	10
6	1.00	0.60	0.75	10
8	0.86	0.60	0.71	10
9	1.00	1.00	1.00	10
Doğruluk:			0.77	70
Makro Ortalama:	0.80	0.77	0.77	70
Mikro Ortalama:	0.80	0.77	0.77	70

Çizelge 5.5. Karar Ağaçları Sınıflandırıcısı Hassasiyet - Duyarlılık - Destek Sonuçları, K=10

12	100	0	0	0	0	0	0
3	0	80	0	20	0	0	0
4	10	10	70	0	0	10	0
5	30	0	0	70	0	0	0
6	10	0	20	10	60	0	0
8	0	0	30	10	0	60	0
9	0	0	0	0	0	0	100
	12	3	4	5	6	8	9

**Predicted Label**

Çizelge 5.6. Karar Ağaçları Sınıflandırıcısı Hata Matrisi, K=10

### 5.3 K-En Yakın Komşuluğu

K-En Yakın Komşuluğu Sınıflandırıcısı, 4.4.1.5 bölümünde kuramsal olarak açıklanmıştır. KNN, sklearn Python kütüphanesi üzerinden 5.4 kod parçacığı ile kullanılmıştır.

```
from sklearn.neighbors import KNeighborsClassifier
```

```
model5 = KNeighborsClassifier(3)
```

---

Listing 5.4. K-En Yakın Komşuluğu sklearn Python Kod Parçacığı

Sınıflandırıcının test verisi (eğitim veri setinde yer almayan) karşısındaki komşuluk sayısı 3 olarak seçildiğinde, başarımı %94,28 olmuştur. Sınıflandırıcının başarımını değerlendirmek için kullanılan "Hassasiyet - Duyarlılık - f-1 Değeri" Çizelge 5.5 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen başarımları Çizelge 5.6 tablosuyla verilmiştir. K-En Yakın Komşuluğu Sınıflandırıcısı'nda komşuluk değerinin değişiminin doğruluk değerine etkisi aşağıda verilmiştir:

- Komşuluk Sayısı : 3, Doğruluk : %94,28
- Komşuluk Sayısı : 5, Doğruluk : %90,00
- Komşuluk Sayısı : 10, Doğruluk : %72,85
- Komşuluk Sayısı : 20, Doğruluk : %78,57
- Komşuluk Sayısı : 100, Doğruluk : %55,71

Sınıflandırıcının başarımını değerlendirmek için kullanılan "Hassasiyet - Duyarlılık - f-1 Değeri" Çizelge 5.5 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen başarımları Çizelge 5.6 tablosuyla verilmiştir.

Hareket	Hassasiyet (precision)	Duyarlılık (recall)	f1-Değeri	Destek (Support)
12	1.00	0.80	0.89	10
3	1.00	1.00	1.00	10
4	1.00	0.90	0.95	10
5	0.82	0.90	0.86	10
6	0.91	1.00	0.95	10
8	0.91	1.00	0.95	10
9	1.00	1.00	1.00	10
<b>Doğruluk:</b>			0.94	70
<b>Makro Ortalama:</b>	0.95	0.94	0.94	70
<b>Mikro Ortalama:</b>	0.95	0.94	0.94	70

Çizelge 5.7. KNN - Hassasiyet - Duyarlılık - Destek Sonuçları, K=10

12	80	0	0	20	0	0	0
3	0	100	0	0	0	0	0
4	0	0	90	0	10	0	0
5	0	0	0	90	0	10	0
6	0	0	0	0	100	0	0
8	0	0	0	10	0	100	0
9	0	0	0	0	0	0	100
	12	3	4	5	6	8	9

**Predicted Label**

Çizelge 5.8. KNN Sınıflandırıcı Hata Matrisi, K=10

### 5.3.1 Yapay Sinir Ağları (MLP)

MLP Sınıflandırıcısı, 4.4.2 bölümünde kuramsal olarak açıklanmıştır. MLP, sklearn Python kütüphanesi üzerinden 5.5 kod parçacığı ile kullanılmıştır.

```
from sklearn.neural_network import MLPClassifier

model = MLPClassifier(alpha=5, max_iter=1000)
```

Listing 5.5. MLP sklearn Python Kod Parçacığı

Sınıflandırıcının başarımını değerlendirmek için kullanılan "Hassasiyet - Duyarlılık - f1-Değeri" Çizelge 5.9 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen doğruluğu Çizelge 5.10 tablosuyla verilmiştir.

Hareket	Hassasiyet (precision)	Duyarlılık (recall)	f1-Değeri	Destek (Support)
12	0.91	1.00	0.95	10
3	1.00	1.00	1.00	10
4	1.00	0.90	0.95	10
5	1.00	1.00	1.00	10
6	1.00	1.00	1.00	10
8	1.00	1.00	1.00	10
9	1.00	1.00	1.00	10
<b>Doğruluk:</b>			0.99	70
<b>Makro Ortalama:</b>	0.99	0.99	0.99	70
<b>Mikro Ortalama:</b>	0.99	0.99	0.99	70

Çizelge 5.9. MLP Sınıflandırıcısı - Hassasiyet Duyarlılık - Destek Sonuçları, K=10

12	100	0	0	0	0	0	0
3	0	100	0	0	0	0	0
4	10	0	90	0	0	0	0
5	0	0	0	100	0	0	0
6	0	0	0	0	100	0	0
8	0	0	0	0	0	100	0
9	0	0	0	0	0	0	100
	12	3	4	5	6	8	9
	Predicted Label						

Çizelge 5.10. MLP Sınıflandırıcı Hata Matrisi, K=10

### 5.3.2 Topluluk Öğrenmesi

Topluluk Öğrenmesi Yöntemleri, 4.4.1.6 bölümünde kuramsal olarak açıklanmıştır. KNN, sklearn Python kütüphanesi üzerinden 5.6 kod parçacığı ile kullanılmıştır. Her sınıflandırıcı, daha önce veri kümesinde görülmemiş olan verileri sınıflandırma yeteneğine sahiptir. Örneğin, SVM sınıflandırıcısı, karar ağaçlarının sınıflayamadığı bir test verisini doğru şekilde sınıflandırabilir. Bu nedenle, daha önce veri modelinde görülmemiş bir test verisini sınıflandırmak için, EL sınıflandırıcı tüm sınıflandırıcıların katkısını sağlamak için eşit olarak ağırlıklandırılmıştır.

```

from ...

model1 = SVC(kernel="linear", C=5, probability=True)
model2 = CalibratedClassifierCV(base_estimator=LinearSVC(random_state=0,
    tol=1e-5, max_iter=1000000, penalty='l2', dual=False), cv=20)
model3 = DecisionTreeClassifier(max_depth=50)
model4 = MLPClassifier(alpha=5, max_iter=1000)
model5 = KNeighborsClassifier(3)

model_ensemble = VotingClassifier(estimators=[('Linear_SVM', model1),
    ('Calibrated SVM', model2), ('Decision Tree', model3), ('MLP', model4),
    ('KNN', model5)], voting='hard', weights=[2, 2, 2, 2, 2])

```

Listing 5.6. Topluluk Öğrenmesi Yöntemi sklearn Python Kod Parçacığı



Topluluk öğrenmesi yönteminde eşit ağırlıklı olarak tezimiz kapsamında kullanılan sınıflandırıcılardan Sınıflandırıcının başarımını değerlendirmek için kullanılan "Hassasiyet - Duyarlılık - f-1 Değeri" Çizelge 5.11 tablosu aşağıda verilmiştir. Sınıflandırıcının egzersiz hareketlerine karşılık gelen başarımları Çizelge 5.12 tablosuyla verilmiştir.

Exercise	Precision	Recall	f1-Score	Support
12	1.00	1.00	1.00	10
3	1.00	1.00	1.00	10
4	1.00	0.90	0.95	10
5	1.00	1.00	1.00	10
6	0.91	1.00	0.95	10
8	1.00	1.00	1.00	10
9	1.00	1.00	1.00	10
Accuracy:			0.99	70
Macro Average:	0.99	0.99	0.99	70
Micro Average:	0.99	0.99	0.99	70

Çizelge 5.11. Topluluk Öğrenmesi Sınıflandırıcı - Duyarlılık - Destek Sonuçları, K=10

12	100	0	0	0	0	0	0
3	0	100	0	0	0	0	0
4	0	0	90	0	10	0	0
5	0	0	0	100	0	0	0
6	0	0	0	0	100	0	0
8	0	0	0	0	0	100	0
9	0	0	0	0	0	0	100
	12	3	4	5	6	8	9

Predecied Label

Çizelge 5.12. Topluluk Öğrenmesi Sınıflandırıcı Hata Matrisi (Confusion Matrix), K=10

## 6. SANAL FİZYOTERAPİ EGZERSİZ SİSTEMİ TASARIMI

Fizyoterapi ve rehabilitasyon seansları genel olarak iki aşamadan oluşur. İlk aşamada; hasta, fizyoterapist tarafından egzersiz hareketlerini öğrenir ve fizyoterapist gözetiminde bu egzersiz hareketlerini yapmaya çalışır. Eğer hasta hareketleri yanlış yaparsa fizyoterapist tarafından geri bildirim alarak egzersiz hareketini doğru yapmaya çalışır. İkinci aşama ise; hastanın kendi başına evde gerçekleştirdiği egzersiz hareketleridir. Hastaya fizyoterapist tarafından hazırlanan bir egzersiz programı verilir. Bu program hasta ile fizyoterapistin birlikte seansta çalıştığı hareketler olabileceği gibi hastanın hiç görmediği hareketler de olabilir. Fizyoterapist bu hareketleri anlatarak ya da hareketin nasıl yapılacağına tarif edildiği bir broşür vererek hastayı yönlendirir. Sanal Egzersiz Sistemi (ViTES), birinci aşamada kullanılabileceği gibi özellikle ikinci aşamadaki problemlerin çözümünü amaçlar ve ikinci aşamanın içerdiği süreci iyileştirmeye odaklanır. İkinci aşamada hasta kendi başınadır ve ilk aşamada yer alan fizyoterapist geri bildirim bulunmaz. Bu yüzden hasta egzersiz hareketlerini yanlış yapabileceği gibi sakatlanmalara da neden olabilir. Bu aşamada ViTES uygulaması sayesinde hasta hareketi doğru yapıp yapmadığı konusunda geri bildirim alabilir, gözetimli bir ev egzersiz ödevini gerçekleştirebilir. Bu sürece fizyoterapist açısından bakıldığında ise hastanın hangi hareketi kaç tekrar yaptığı uygulama ile ne kadar zaman geçirdiği yani egzersizlere evde yeterli süre ayırıp ayırmadığını gözlemleyebilir. Hastanın egzersiz hareketini ne doğrulukta yaptığını gözlemleyebilir ve doğru yapılmayan hareketlere önem vererek tedavi programını buna göre hastaya özgü olarak kurgulayabilir. Uygulamanın "Yeniden Egzersiz Görselleme" özelliği ile hastanın yapmış olduğu hareketleri video olarak izleyebilir ve yanlış yapılan hareketleri analiz edebilir. Tezimiz kapsamında oluşturulan veri setlerine "Veri Seti" 3 bölümünden erişilebilir. Bu veri setleri kullanılarak ViTES uygulaması kapsamında A3 (Wand Egzersizi - Omuz Fleksiyonu), A4 (Wand Egzersizi - Omuz Abduksiyonu), A5 (Omuz Posterior Kapsül Germe), A6 (90 ° Omuz Fleksiyonu), A8 (90 ° Skapular Düzlemde Omuz Elevasyon), A9 (Eksternal Rotasyon Yönünde Germe) ve A12 (Dirsekler Fleksiyonda Skapular Retraksiyon) egzersiz hareketlerine yoğunlaşmıştır. Bu hareketlerin seçilme nedeni veri setlerinde bu hareketlerin diğerlerine göre daha çok tekrarlanmasından ve 12 hareket ile yapılan gerçek zamanlı bir sınıflandırma probleminde başarımının düşük olma olasılığının önüne geçme nedeninden dolayıdır.

## 6.1 İstemci Mimarisi

Sanal Egzersiz sisteminin istemci tarafı Unity 2017.2.0f3 oyun motorundan yararlanılarak geliştirilmiştir. Fizyoterapistin vermiş olduğu ev ödevi olarak tanımlanan fizyoterapi omuz egzersizlerini ev ortamında yapmasını kolaylaştıran ve bu süreci oyunlaştırma ile tedavi sürecine bağlılığı arttırılması nihai hedefi göz önüne alınarak tasarlanmıştır. İstemci uygulama kullanıcının başlat komutundan sonra egzersiz hareketlerini yaparken hiçbir fare-klavye işlevi gerektirmeksizin hareketleri sıralı bir şekilde sesli ve yazılı komutlar aracılığıyla yapabileceği şekilde tasarlanmıştır. Tezimiz kapsamında oluşturulmuş olan omuz fizyoterapi egzersizlerini içeren veri setleri kullanılarak veri madenciliği algoritmaları kullanılarak eğitilmiş bir modelini sunucu mimarisine girdi olarak alacak, ve istemci mimarisi gerçek zamanlı olarak hastanın yaptığı hareketlerin hangi egzersize ait olduğunu ve ne ölçüde ilgili egzersize benzediğini yüzdelik olarak hastaya sunmaktadır. Bu sayede hasta yapmış olduğu egzersiz hakkında bir geri bildirim almış olacaktır ve bir fizyoterapistin hareketi anlık olarak incelemesi ve fizyoterapi merkezinde bulunmadan da gözetimli bir şekilde fizyoterapi egzersizlerini yapmış olması sağlanacaktır.


### 6.1.1 Egzersiz Yeniden Görselleme

Kullanıcının yaptığı egzersiz hareketlerinin daha sonra incelemek üzere Kinect kamerasının sağladığı RGB resimler ile videoya dönüştürülerek kaydedildiği modüldür. Bu videolar istemci uygulamaya kaydedilir ve fizyoterapist ile istek doğrultusunda paylaşılır. Ayrıca verilerin istemci tarafında tutulmasının bir diğer nedeni ise RGB gibi boyutu yüksek verilerin gerçek zamanlı işlemler yaparken ağda taşınmasının önüne geçilme amacındandır.


### 6.1.2 Ayarlar Menüsü

ViTES uygulamasında yer alan konfigürasyonların ayarlanabildiği istemci uygulama tarafında yer alan ekrandır. Bu ekran ile "Ana Ayarlar" menüsünden aşağıdaki ayarlara erişim sağlanabilir:


- Kullanıcı Adı : Egzersiz hareketlerini yapacak olan kullanıcının adı.



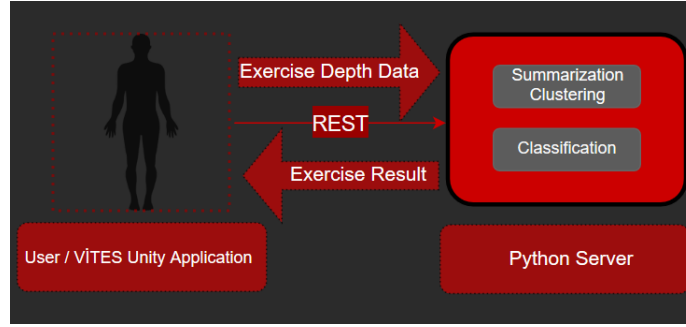
Şekil 6.1. Ana Ayarlar Menüsü



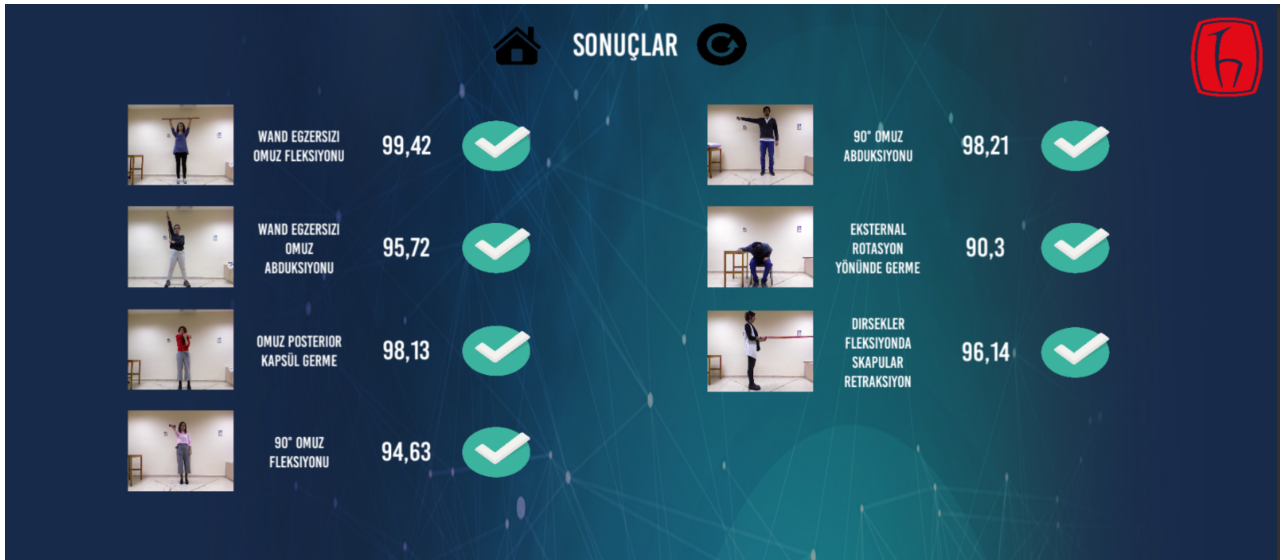
Şekil 6.2. Sanal Egzersiz Sistemi VITES - Unity3D Oyunu Ekran Görüntüsü



Şekil 6.3. Egzersiz Oluşturma Ayarları Menüsü



Şekil 6.4. Sanal Egzersiz Sistemi VİTES Mimarisi



Şekil 6.5. Sonuç Ekranı

- Sunucu URL : Sunucu uygulamanın kurulmuş olduđu IP adresi ve portu.
- Egzersiz Yeniden Oluřturma URL : Egzersiz Hareketlerinin video olarak istemci tarafında oluşturulacađı dizin.
- Yeniden Grselleme Aktifliđi : Yeniden grselleme yapmak gerek zamanlı olarak hareket tanımaya performans olarak etki ettiđi iin bu ayar ile birlikte minimum sistem gereksinimlerine sahip olmayan istemci uygulama kurulu bilgisayarlar iin kapalı olması nerilir.
- Egzersiz Oluřturma Ayarları : Bu mende ise fizyoterapist tarafından kullanıcının hangi hareketleri yapması gerektiđine karar verilir.

Ana ayarlar mens (kullanıcı adı, sunucu URL vb.) ile ilgili ekran grntsne Őekil 6.1 Őekilden eriřilebilir. Buna ek olarak "Egzersiz Oluřturma Ayarları"na Őekil 6.3 Őeklinden ulařılabilir.

### **6.1.3 Demo Modu**

ViTES uygulamasının kullanıcı ya da fizyoterapist tarafından anlaşılmasını kolaylařtırılmak amalı oluşturulmuřtur. Demo verilerle tm akıřı gstermeye ve uygulamayı đretme amacı yerine getirilmeye alıřılmıřtır. Ayrıca bu mod uygulamanın bařtan uca testini de gereklemektedir.

### **6.1.4 ViTES Uygulaması Akıřı**

ViTES uygulamasının istemci yazılımı aılır. ncelikle "Ayarlar" 6.1.1 mens kullanılarak gerekli ayarlar yapılır. Daha sonra "Yeni Terapi" alanına tıklanarak Őekil 6.2 Őeklinde belirtilen ekran ile karřılařılır. Bu ekran yatayda ikiye blnmřtr ve solda yer alan 1 numaralı blmde hareketin fizyoterapistler tarafından yapılan hali video olarak kullanıcıya gsterilmektedir. 2 numaralı alanda ise gerek zamanlı olarak tanınan kullanıcının kemik bilgisi eklenmiř resmi grnmektedir ve gerek zamanlı olarak bu alan gncellenmektedir. 3 numaralı alanda kullanıcı adı bilgisi, 4 numaralı alanda Kinect'in bađlı olup olmadıđına dair gsterge bulunmaktadır. 5 numaralı alanda hareketin yapılacađı sre yer alır. 6 numaralı alanda ise Kinect kamerasının sizi dođru tanıyıp tanımadıđını

belirten (kalibrasyon gerekliliğini) gösterge bulunur. 7 numaralı alanda sesli komutlarla aynı olan uyarı metni yer alır. 8 numaralı alan hareket sonucunu ve doğruluk yüzdesini göstermek için kullanılmıştır. 9 numaralı alan ile ana menüye dönebilir, o anlık hareketi durdurabilir, hareketi tekrar yapmayı seçebilir veya ilgili hareketi yapmaktan vazgeçip bir sonraki harekete geçiş yapabilirsiniz. Ek olarak 1 numaralı alanda yer alan videonun süreleri konumlandırılmıştır. 10 numaralı alanda ise o anda yapılacak olan hareketin adı belirtilir ve kaç hareket yapacağınız bilgisi verilir.

Kullanıcı Şekil 6.2 menüsünü açtığı anda egzersiz hareketlerini yapmaya başlamaya hazırdır. Öncelikle bu şekildeki 4 numaralı alanı kontrol ederek "Kinect" sembolünü görür ve Kinect ile kurulumun yapıldığı cihaz (bilgisayar, TV vs.) arasında bağlantı kurulduğundan emin olur. Daha sonra 6 numaralı alandaki "iskelet figürünün" üzerinde kırmızı çizgi olmadığını görene kadar hareket eder ve Kinect cihazının kullanıcıyı görmesi sağlanır. Bu sayede Kinect kalibre olur ve "iskelet" sembolünün üzerindeki kırmızı çizgi yok olur ayrıca kullanıcı kendini 2 numaralı alanda kemikleri işaretlenmiş olarak gözlemler. Bu aşamadan sonra hareketi yapmaya hazırdır. Şekil 6.2 şeklinde belirtilen 1 numaralı alandaki egzersiz hareketi videosu izlenir ve hareket kullanıcı tarafından öğrenilmiş olur. Daha sonra bildirim sesi ile birlikte kullanıcı öğrendiği hareketi yapmaya başlar. İkinci bildirim sesi ile hareket bitirilir ve 8 numaralı alanda hareketi doğru yapıp yapmadığına dair bildirim alır. Hareketi tekrar etme, diğer harekete geçme gibi işlemler 9 numaralı alandan yapılır. 10 numaralı alanda belirtilen hangi hareketin yapıldığı alanda ayrıca kaç hareket yapılacağı bilgisi verilmektedir. Son hareketinde yapılması ile birlikte sonuç ekranı gözlemlenir (sonuç ekranına Şekil 6.5 şeklinden erişilebilir). Kullanıcıya detaylı olarak hangi hareketi ne doğrulukta yaptığının bilgisi verilir. Daha sonra kullanıcı aynı hareket seti ile tekrar egzersiz yapabileceği gibi anasayfaya da dönebilir.

## **6.2 Sunucu Mimarisi**

ViTES tasarımında veri madenciliği ile egzersizlerin modellenmesi ve analiz edilmesi, hastaya özgü fizyoterapi egzersizlerinin arşivlenmesi, hasta ve fizyoterapistlerin sistemdeki kimliklerinin doğrulanması ve yetkilendirilmesi gibi işlemler yapılmaktadır. Bu işlemleri yaparken sunucu mimarisindeki teknolojiler gelecekteki sorunlara ve uygulamanın kullanılabilirliğine odaklanılarak seçilmiştir. Bu teknolojiler; sunucu mimarisinde

Python dili kullanılarak geliştirilmiştir. ViTES istemci uygulamasından kullanıcı tarafından yapılan egzersiz hareketleri (birçok kare "frame" içeren derinlik bilgisi) sunucu uygulamaya REST mimarisi altyapısı kullanılarak POST isteği olarak iletilir. Sunucu tarafından alınan bu istek, öncelikle kümelenme ("Hareket Özetleme Yöntemi" bölümü Şekil 5.1) işlemine sokulur. K-means algoritması ile çok sayıdaki kare sayısı 10 adet egzersiz hareketini en iyi temsil eden "egzersizi en iyi temsil eden kareler"e dönüştürülür. Daha sonra sunucu tarafında bu çerçeveler sınıflandırma modülüne sorularak yapılmış olan hareketin hangi harekete benzediğini ve ne doğrulukta benzediğini bulur ve aynı istek üzerinden istemci uygulamaya cevap dönülür. Bu REST mimarisindeki POST isteği 0.5 milisaniyenin altında gerçekleştirilir. Uygulamanın sunucu mimarisi, Şekil 6.4 şekliyle belirtilmiştir. Ayrıca veri madenciliği katmanı ve istemci-sunucu haberleşme teknolojisi olarak tercih edilen Temsili Durum Transfer Servis (REST) mimarisi bu bölümde anlatılacaktır.

### **6.2.1 Temsili Durum Transfer Servis (REST) Yaklaşımı**

Temsili Durum Transferi Servisi (REST) Mimarisi, altyapısal olarak belirli kısıtlamalar ve özellikler tanımlayarak HTTP protokolü tabanlı olarak sistemler arası birlikte işlerliği, iletişimi sağlar. Veri tipi olarak yazı temelli (text based), JSON, XML, HTML tabanlı veri transferi sağlayabilir. ViTES uygulamasında istemci ve sunucu tarafında nesne yönelimli olarak egzersiz verisi modellenmiştir bu veriler ham veri (yazı temelli olarak) üzerinden istemciden sunucuya iletilir. Benzer şekilde egzersiz verisinin sonucu veya kimlik doğrulama verileri bu mimari ile istemci-sunucu arasında taşınmaktadır. Bu mimarinin birçok artısının olması yanı sıra ViTES istemci uygulamasının gelecekteki çalışmalarda başka platformlara taşınması gerekliliğine uygunluğundan seçilmiştir. Diğer bir artısı ise, Python ile oluşturulan sunucu uygulamasının REST mimari ile çok hızlı bir şekilde veri aktarımını sağlayabilmesidir.

### **6.2.2 Veri Madenciliği Katmanı**

Veri madenciliği, büyük miktardaki verideki daha önceden bilinmeyen örüntüleri seçme, keşfetme ve modelleme sürecidir [53]. Ek olarak; Veri madenciliği, SAS Enstitüsü tarafından, "büyük miktardaki verideki ilişkileri araştırmak ve modellemek için kullanılan ge-



lişmiş yöntemlerdir" olarak tanımlanmıştır. Tezimiz kapsamında oluşturulmuş olan omuz fizyoterapisinde kullanılan egzersizleri içeren veri setleri veri madenciliği algoritmaları kullanılarak gözetimli eğitim yöntemleri ile Python dili ve skilearn kütüphanesi kullanılarak eğitilmiştir. Bu eğitimde birçok sınıflandırıcı kullanılarak başarımları test edilmiştir. İstemci tarafından yapılan POST istekler, sunucu tarafında hareket özetleme ve sınıflandırma işlemlerinden sonra aynı istek üzerinden yine istemci uygulamaya iletilir.

### 6.3 Kinect Mimarisi

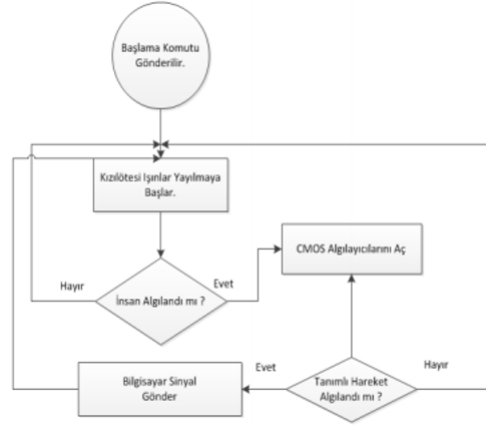
Tezimiz kapsamında Kinect for Xbox 360 cihazı, omuz fizyoterapisinde yapılan egzersizlerde, hastanın veya veri seti oluşturmada fizyoterapistlerin kemiklerinin konum verisini almada kullanılmıştır.

Kinect'in teknik özellikleri aşağıdaki gibi belirtilmiştir [11]:

- 1.3 mega piksel renkli kamera,
- Renk ve derinlik algılama lensleri, kızılötesi derinlik sensörü, kızılötesi verici ve renk sensörü,
- IR (kızılötesi) geçiren filtre ile donatılmış kamera (derinlik algılama amaçlı),
- CMOS derinlik kamerası,
- Kare (frame) Hızı: 30 kare/saniye (FPS),
- 640 x 480 piksel resim çözünürlük,
- Ses algılayıcı mikروفon. Ses Formatları: 16-kHz, 24-bit mono PCM,
- Yatay görüş alanı: 57 derece,
- Dikey görüş alanı: 43 derece,
- Fiziksel Tilt alanı: 27 derece
- Derinlik sensörü alanı: 1.2m - 3.5m.

Kinect'in üzerinde 2 tane derinlik kamerası, 1 tane YKB kamera, 2 tane mikrofon ve hareket sağlayıcı bir motor mekanizması (tilt motoru) bulunmaktadır. Kinect'in sensör yapısı CMOS kamera lazer projeksiyonu yaparken, kızılötesi sensör bu kemiklerin gidiş - geliş süresini hesaplayarak 320x240 çözünürlüğünde her bir noktanın mesafesini bildirmektedir.

Kinect içerisindeki gömülü yazılım ise bu veriler yardımıyla iskelet yapısını hesaplamakta ve bunu Xbox'a ya da bilgisayara göndermektedir. Kinect'in insan tanıma algoritması Şekil 6.6 şeklinde verilmiştir. Kinect, insan vücudunun bir kısmı görüş alanının dışında kalsa bile, iskelet yapısının görünmeyen kısmını eski verilere bakarak ya da eklem noktalarının bilgilerini kullanarak tahmin edebilmektedir. Bu sayede her bir kemiğin konumunu kayıp etmeden verebilmektedir; ancak görülmeyen kemikler için verilen konum verileri tahmini olmaktadır.



Şekil 6.6. Kinect İnsan Tanıma Algoritması

Kinect teknolojisinin bilgisayarda verimli çalışabilmesi için gerekli minimum donanım gereksinimleri ve yüklenmesi gereken yazılımlar aşağıdaki gibi verilmiştir (Kinect, 2010).

- Windows 7 (x86 veya x64),
- Dual-Core 2.66 GHZ veya daha hızlı bir işlemci,
- 2GB Ram,

- Visual Studio 2010,
- .NET Framework 4.0,
- DirectX SDK,
- DirectX End-User Runtime,

#### **6.4 Unity Kinect Entegrasyonu**

Bu bölümde kullanıcının eklem konum verisi iskelet olarak sanal ortamın modellenmesi yapılmıştır. Kullanıcının her yaptığı hareket gerçek zamanlı olarak ekrana üzerine iskelet verisi eklenerek yansıtılmaktadır. Konum verisine Microsoft Kinect SDK 1.8 ile erişim sağlanmaktadır. Kinect ile Unity entegrasyonu işleminde, sesle komut sistemi de ele alınmıştır.

Gözetimli mod seçildiği anda, fizyoterapist tarafından hastaya özgü olarak hazırlanmış olan programa ait egzersizler hastaya gösterilir ve sıralı bir şekilde hangi hareketi yapacağını isim olarak görmüş olur. Sırası gelen için egzersiz içinse fizyoterapistin ilgili hareketin nasıl yapıldığını anlatmak için oluşturulmuş olduğu videoları izleyerek bu hareketlere hazırlanmış olacaktır.

## 7. SONUÇLAR

### 7.1 Veri Madenciliği Sonuçları

ViTES sisteminin geliştirilmesi amacıyla oluşturulmuş veri setleri kullanılarak Destek Vektör Makineleri, Kalibre Edilmiş Destek Vektör Makineleri, K-En Yakın Komşuluğu, Karar Ağaçları, MLP ve bunların eşit ağırlıkla oylanarak sonuç bulan Topluluk Öğrenmesi sınıflandırıcıları kullanılarak sınıflandırıcı modelleri oluşturulmuştur. Bu sınıflandırıcıların değerlendirmeleri hassasiyet, duyarlılık, f-1 değeri gibi metrikler kullanılarak ve 5 katmanlı çapraz doğrulama (5-fold validation) kullanılarak değerlendirilmiştir. Başarım sonuçlarına "Omuz Fizyoterapi Hareketlerinin Sınıflandırılması" 5 bölümünde detaylı olarak yer verilmiştir. Özetlemek gerekirse doğruluk değerleri aşağıdaki gibidir:

- Destek Vektör Makineleri Sınıflandırıcısı : 0.9857
- Kalibre Edilmiş Destek Vektör Makineleri Sınıflandırıcısı : 0.9714
- K-En Yakın Komşuluğu Sınıflandırıcısı : 0.9428
- Karar Ağaçları Sınıflandırıcısı : 0.7714
- Yapay Sinir Ağları Sınıflandırıcısı : 0.9857
- Topluluk Öğrenmesi Sınıflandırıcısı : 0.9857

Bu sonuçlar incelediğinde sınıflandırıcıların performansları başarılıdır ve modellenmeye ve öğrenilmeye çalışılan fizyoterapi egzersiz hareketleri başarılı şekilde sınıflandırılmaktadır. Tüm sınıflandırıcılara bakıldığında göreceli olarak Karar Ağaçları ve K-En Yakın Komşuluğu sınıflandırıcılarında veri setimizin başarımı düşüktür; ancak Topluluk Öğrenmesi sınıflandırıcı yöntemiyle bu sınıflandırıcılarında başarımı arttırılmaya çalışılmıştır ve bu sayede sadece gerçek zamanlı bir sistem olan ViTES'de tüm sınıflandırıcıların katkısıyla oylanarak kullanıcı tarafından yapılan egzersiz hareketinin başarımı ve hangi sınıfa ait olduğu %98.57 sınıflandırıcı doğruluk başarımıyla tespit edilmiş olur.

## 7.2 ViTES Sanal Egzersiz Sistemi'nin Etkinliğinin Araştırılması

ViTES uygulamasının etkinliğinin araştırılması amacıyla omuz fizyoterapi hareketlerini bilmeyen kullanıcıların kullanımına sunulmuştur. 10 kişiden oluşan bu kullanıcılar, iki gruba ayrılarak ViTES sistemini kullanarak gerçek zamanlı olarak belirlenen 7 egzersiz hareketini yapmışlardır. Her iki grup kullanıcıya da uygulamayı nasıl kullanacakları hakkında bilgi verilirken egzersiz hareketleri hakkında bilgi verilmemiştir. 1. Grupta yer alan kullanıcılar, egzersiz hareketlerini yalnızca fizyoterapist tarafından öğrenip (ViTES uygulamasında eğitim almadan), egzersiz hareketlerini yapmıştır. 2. Grupta yer alan kullanıcılar ise fizyoterapist tarafından hiç geri bildirim almadan, egzersiz hareketlerini ViTES uygulaması üzerinden öğrenip, egzersiz hareketlerini yapmıştır. Bu sayede yaş, kilo ve uzunluk olarak dengeli olan bu iki gruba ayrılan kullanıcılar sayesinde ViTES uygulamasının ev ödev egzersizlerinde kullanılabilirliği ve etkinliği incelenmiştir.

1. Grupta yer alan kullanıcılar, egzersiz hareketini fizyoterapistin göstermesinin ardından ViTES uygulaması ile egzersiz hareketlerini tekrar etmişler. Bu grupta yer alan egzersizlerin hiçbiri ViTES uygulaması tarafından yanlış bulunmamıştır. Yapılan egzersiz hareketlerinin yapılması beklenen harekete benzerlik sonuçları Çizelge 7.1 tablosunda verilmiştir.

	Hareket 1	Hareket 2	Hareket 3	Hareket 4	Hareket 5	Hareket 6	Hareket 7	Yaş	Sağlık	Cinsiyet
<b>Kullanıcı 1</b>	%97,87	%95,58	%97,30	%96,44	%96,95	%99,40	%98,69	18	SLAP Rahatsızlığı	K
<b>Kullanıcı 2</b>	%97,52	%97,77	%95,14	%94,97	%96,51	%92,46	%97,99	44	Diz, bel rahatsızlığı	E
<b>Kullanıcı 3</b>	%96,41	%98,35	%95,34	%97,85	%96,17	%96,87	%96,67	39	Omuz Ağrısı, Boyun Fıtığı	K
<b>Kullanıcı 4</b>	%94,48	%99,13	%89,78	%92,73	%87,01	%97,74	%96,85	21	Sağlıklı	K
<b>Kullanıcı 5</b>	%98,00	%70,68	%77,35	%92,29	%82,05	%96,17	%96,14	27	Sağlıklı	K
<b>Ortalama</b>	<b>%96,85</b>	<b>%92,30</b>	<b>%90,98</b>	<b>%94,85</b>	<b>%91,73</b>	<b>%96,52</b>	<b>%97,26</b>	29,8	<b>2 Sağlıklı / 3 Rahatsızlık</b>	<b>4 K / 1 E</b>

Çizelge 7.1. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 1. Grup (En iyi Kare Sayısı: 10, SVM)

2. Grupta yer alan kullanıcılar, hiçbir fizyoterapist geri bildirim almadan sadece ViTES üzerindeki eğitim videolarını bir defa izledikten sonra hareketleri tekrar etmişlerdir. Bu grupta yer alan egzersizlerin hiçbiri ViTES uygulaması tarafından yanlış bulunmamış başka bir deyişle kullanıcıların hiçbiri hareketleri yanlış yapmamışlardır. Bu egzersiz hareketlerinin yapılması beklenen egzersiz hareketlerine olan benzerliklerini içeren so-

nuçlara Çizelge 7.2 tablosundan erişilebilir.

	Hareket 1	Hareket 2	Hareket 3	Hareket 4	Hareket 5	Hareket 6	Hareket 7	Yaş	Sağlık	Cinsiyet
<b>Kullanıcı 1</b>	%98,35	%97,13	%98,67	%62,42	%93,68	%96,36	%99,63	28	Sağlıklı	K
<b>Kullanıcı 2</b>	%97,12	%98,86	%94,54	%95,86	%96,29	%95,92	%93,98	22	Sağlıklı	E
<b>Kullanıcı 3</b>	%83,16	%94,33	%37,19	%96,06	%84,92	%98,77	%97,45	19	Boyun Düzleşmesi	K
<b>Kullanıcı 4</b>	%98,93	%99,79	%75,15	%96,65	%97,85	%83,68	%89,86	45	Sağlıklı	E
<b>Kullanıcı 5</b>	%98,73	%99,03	%94,56	%80,66	%98,15	%96,10	%94,05	26	Sağlıklı	E
<b>Ortalama</b>	<b>%95,25</b>	<b>%97,82</b>	<b>%80,02</b>	<b>%86,33</b>	<b>%94,17</b>	<b>%94,16</b>	<b>%94,99</b>	<b>28</b>	<b>4 Sağlıklı / Rahatsız</b>	<b>2 K / 3 E</b>

Çizelge 7.2. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 2. Grup (En iyi Kare Sayısı: 10, SVM)

Sonuç olarak Çizelge 7.1 ve Çizelge 7.2 tabloları incelendiğinde egzersiz hareketlerini sadece fizyoterapistten öğrenen grup ile sadece ViTES uygulaması üzerinden öğrenen grupların sonuçları benzerlik göstermektedir. Tablolarda yer alan ortalamalar incelendiğinde, egzersiz hareketlerini fizyoterapistten öğrenen grubun başarımları Hareket-4 hariç daha yüksektir; ancak sonuçların arasında büyük farklar olmaması sebebiyle ViTES uygulamasının ev ödevi egzersizlerinde kullanımının etkinliği yüksektir. Tabloda yer alan Hareket-4 alanı incelendiği ortalama olarak, 2. gruba ait olan kullanıcıların başarımları daha yüksektir yani kullanıcılar egzersiz hareketlerini fizyoterapistin gözetimi dışında ViTES uygulamasından daha iyi öğrenmişlerdir.

	Hareket 1	Hareket 2	Hareket 3	Hareket 4	Hareket 5	Hareket 6	Hareket 7	Sağlık	Cinsiyet
<b>Kullanıcı 1</b>	%97,87	%95,58	%97,30	%96,44	%96,95	%99,40	%98,69	SLAP Rahatsızlığı	K
<b>Kullanıcı 2</b>	%97,52	%97,77	%95,14	%94,97	%96,51	%92,46	%97,99	Diz, bel rahatsızlığı	E
<b>Kullanıcı 3</b>	%96,41	%98,35	%95,34	%97,85	%96,17	%96,87	%96,67	Omuz Ağrısı, Boyun Fıtığı	K
<b>Kullanıcı 4</b>	%94,48	%99,13	%89,78	%92,73	%87,01	%97,74	%96,85	Sağlıklı	K
<b>Kullanıcı 5</b>	%98,00	%70,68	%77,35	%92,29	%82,05	%96,17	%96,14	Sağlıklı	K
<b>Kullanıcı 6</b>	%98,35	%97,13	%98,67	%62,42	%93,68	%96,36	%99,63	Sağlıklı	K
<b>Kullanıcı 7</b>	%97,12	%98,86	%94,54	%95,86	%96,29	%95,92	%93,98	Sağlıklı	E
<b>Kullanıcı 8</b>	%83,16	%94,33	%37,19	%96,06	%84,92	%98,77	%97,45	Boyun Düzleşmesi	K
<b>Kullanıcı 9</b>	%98,93	%99,79	%75,15	%96,65	%97,85	%83,68	%89,86	Sağlıklı	E
<b>Kullanıcı 10</b>	%98,73	%99,03	%94,56	%80,66	%98,15	%96,10	%94,05	Sağlıklı	E
<b>Ortalama</b>	<b>96,05</b>	<b>95,06</b>	<b>93,01</b>	<b>90,59</b>	<b>92,95</b>	<b>95,34</b>	<b>96,13</b>	<b>6 Sağlıklı / 4 Rahatsızlık</b>	<b>6 K / 4 E</b>

Çizelge 7.3. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri (En iyi Kare Sayısı: 10, SVM)

Çizelge 7.1 ve Çizelge 7.2 tabloları birleştirilerek Çizelge 7.3 tablosu oluşturulmuştur ve ViTES uygulaması ile kullanıcıların egzersiz hareketlerini yapmalarının tüm sonuç ve

ortalamları verilmiştir. Tüm hareketlerde ortalama olarak %90 üzerinde bir başarımla benzerlik sonuçları bulunmuştur. Bu da ViTES uygulamasının ev ödevi egzersizlerinde kullanılabilirliğinin yüksek olduğunu gösterdiği gibi klinik seanslarda da hasta yoğunluğu olduğu zamanlarda veya fizyoterapist sayısının az olduğu zamanlarda kullanılabilirliğinin yüksek olduğunu göstermektedir. Bunlara ek olarak, ViTES uygulaması ile yapılan bu testte hiçbir hareket yanlış bulunmamıştır ve bu da uygulamaya olan güveni arttırmaktadır.

### **7.2.1 Likert Araştırması**

Bu kullanıcılara, Hacettepe Üniversitesi Fizyoterapi ve Rehabilitasyon Bölümü akademisyenleriyle birlikte hazırlanan sorular Likert ölçeği kullanılarak sorulmuştur.

Likert ölçeği, 1932 yılında Rensis Likert tarafından Thurstone ölçeğinin basit bir hali olarak "Dereceleme Toplamlarıyla Ölçeklendirme" temelinde geliştirilmiş bir ölçektir. Likert ölçeğinde yer alan sorular araştırılan konu hakkında bir yargı veya görüş içeren ifadelerle katılım düzeyini belirleyen seçenekler içerir. Katılım düzeyi genelde puanlarla ifade edilir ve 1-5 arası katılım düzeyi "en yüksekten en düşüğe" veya "en düşükten en yükseğe" olarak sıralanır. Sayısal bir değer vermek analizi kolaylaştırmak ve matematiksel olarak ifade etme esasına dayanır. Likert ölçeğinin istatistiksel olarak analiz edilmesinde "aritmetik ortalama" yani parametrik yaklaşım kullanılmıştır [10].

Likert ölçeği uyarlanarak, aşağıdaki Çizelge 7.4 tablosundaki sorular kullanıcılara sorulmuş ve ViTES uygulamasının kullanılabilirliği ve etkinliği araştırılmıştır.

	1 / En Olumsuz	2 / Olumsuz	3 / Nötr	4 / Olumlu	5 / En Olumlu
Uygulamayı beğendiniz mi?					
Uygulamayı ev egzersizlerinizde kullanmak ister misiniz?					
Uygulama eğlenceli mi? (Egzersiz yapmak ağırlı bir süreç olabiliyor ve bu da hastanın devamlılığı azaltıyor. Uygulama fizyoterapi sürecine bağlılığı artırır mı?)					
Böyle bir hizmeti Hacettepe Üniversitesi Fizyoterapi ve Rehabilitasyon Bölümü verse memnun olur musunuz?					
Uygulama yaptığınız hareketleri konum verisi olarak (resim ve video değil) kaydederek, egzersizin yapılan süre, doğruluk gibi bilgileri fizyoterapistiniz ile paylaşılacaktır. Bu sayede fizyoterapist hastalığınızın tüm süreçlerine hakim olup, size en uygun tedavi sürecini yürütecektir. Siz bu sizin rahatsızlığınızın çözümüne olumlu katkı yapar mı?					
Uygulama anlaşılır mı?					

**Çizelge 7.4. Likert ölçeğinin Hacettepe Fizyoterapi ve Rehabilitasyon Bölümü'ndeki kullanıcılarına uygulanmış ve Cevap Yüzdeleri**

ViTES uygulamasının test edecek 5 kullanıcının daha önce omuz egzersiz hareketlerini bilmemesine özen gösterilmiştir. Daha sonra uygulamanın kullanım hakkında kısa bilgiler verilmiştir ve fizyoterapistin bir yönlendirmesi olmadan hareketleri uygulama üzerinden öğrenmesi ve tekrar edilmesi sağlanmaktadır. 5 kullanıcı üzerinde yapılan çalışmada 7 omuz egzersiz hareketi test edilmiş ve 60 egzersiz içeren bir veri oluşturulmuştur. Bu veriler ViTES uygulamasının veri madenciliği modülü tarafından analiz edildiğinde %81 oranında bir başarımla elde edilmiştir. Yani uygulama, hastalar tarafından yapılan omuz egzersizlerine bu başarımla doğru olarak tespit etmiş ve kullanıcıya doğruluk (veri setine benzerlik) oranlarını geri bildirim olarak vermiştir. Bu şekilde hasta, fizyoterapistler tarafından oluşturulmuş eğitim setinde yapılmış omuz fizyoterapi hareketlerine ne kadar benzer hareket yaptığı konusunda geri bildirim verilmiş olur. Bu şekilde hasta, fizyoterapistin hastaya özgü belirlediği başarımla oranının altında bir hareketi yaparsa başarımla arttırana kadar o egzersizi yapmasını gerektiğini öğrenmiş olur. Uygulamanın daha fazla hasta ile test edilmesi uygulamanın güvenilirliğini arttıracaktır. 5 hastaya yönlendirilen Likert anketi ile ortalama olarak 3.46/4 sonucu elde edilmiştir.



	Soru 1	Soru 2	Soru 3	Soru 4	Soru 5	Soru 6	Yaş	Sağlık	Cinsiyet	Ortalama
<b>Kullanıcı 1</b>	5	4	2	4	5	5	18	SLAP Rahatsızlığı	K	<b>30 / 35</b>
<b>Kullanıcı 2</b>	5	5	5	5	5	5	44	Diz Bel Rahatsızlığı	E	<b>35 / 35</b>
<b>Kullanıcı 3</b>	4	5	5	5	5	5	39	Omuz Ağrısı, Boyun Fıtığı	K	<b>34 / 35</b>
<b>Kullanıcı 4</b>	5	5	5	5	5	5	21	Sağlıklı	K	<b>35 / 35</b>
<b>Kullanıcı 5</b>	5	5	5	5	5	5	27	Sağlıklı	K	<b>35 / 35</b>
<b>Ortalama</b>	<b>4,8 / 5</b> <b>%96</b>	<b>5 / 5</b> <b>%100</b>	<b>4,4 / 5</b> <b>%88</b>	<b>4,8 / 5</b> <b>%96</b>	<b>5 / 5</b> <b>%100</b>	<b>5 / 5</b> <b>%100</b>	<b>29,8</b>	<b>2 Sağlıklı / 3 Rahatsızlık</b>	<b>4 K / 1 E</b>	<b>-</b>

Çizelge 7.5. Likert sorularına Deney Grubu 1 tarafından verilen cevaplar ve cevap veren kullanıcıların özellikleri

	Soru 1	Soru 2	Soru 3	Soru 4	Soru 5	Soru 6	Yaş	Sağlık	Cinsiyet	Ortalama
<b>Kullanıcı 1</b>	5	5	5	5	5	5	28	Sağlıklı	K	<b>35 / 35</b>
<b>Kullanıcı 2</b>	4	5	5	5	5	4	22	Sağlıklı	E	<b>33 / 35</b>
<b>Kullanıcı 3</b>	5	5	5	5	5	5	19	Boyun Düzleşmesi	K	<b>35 / 35</b>
<b>Kullanıcı 4</b>	4	3	4	4	5	5	45	Sağlıklı	E	<b>25 / 35</b>
<b>Kullanıcı 5</b>	4	3	4	4	4	4	26	Sağlıklı	E	<b>23 / 35</b>
<b>Ortalama</b>	<b>4,4 / 5</b> <b>%88</b>	<b>4,2 / 5</b> <b>%84</b>	<b>4,6 / 5</b> <b>%92</b>	<b>4,6 / 5</b> <b>%92</b>	<b>4,8 / 5</b> <b>%96</b>	<b>4,6 / 5</b> <b>%92</b>	<b>28</b>	<b>4 Sağlıklı / 1 Rahatsız</b>	<b>2 K / 3 E</b>	<b>-</b>

Çizelge 7.6. Likert sorularına Deney Grubu 2 tarafından verilen cevaplar ve cevap veren kullanıcıların özellikleri

	Soru 1	Soru 2	Soru 3	Soru 4	Soru 5	Soru 6	Yaş	Sağlık	Cinsiyet	Ortalama
<b>Kullanıcı 1</b>	5	4	2	4	5	5	18	SLAP Rahatsızlığı	K	<b>30 / 35</b>
<b>Kullanıcı 2</b>	5	5	5	5	5	5	44	Diz, bel rahatsızlığı	E	<b>35 / 35</b>
<b>Kullanıcı 3</b>	4	5	5	5	5	5	39	Omuz Ağrısı, Boyun Fıtığı	K	<b>34 / 35</b>
<b>Kullanıcı 4</b>	5	5	5	5	5	5	21	Sağlıklı	K	<b>35 / 35</b>
<b>Kullanıcı 5</b>	5	5	5	5	5	5	27	Sağlıklı	K	<b>35 / 35</b>
<b>Kullanıcı 6</b>	5	5	5	5	5	5	28	Sağlıklı	K	<b>35 / 35</b>
<b>Kullanıcı 7</b>	4	5	5	5	5	4	22	Sağlıklı	E	<b>33 / 35</b>
<b>Kullanıcı 8</b>	5	5	5	5	5	5	19	Boyun Düzleşmesi	K	<b>35 / 35</b>
<b>Kullanıcı 9</b>	4	3	4	4	5	5	45	Sağlıklı	E	<b>25 / 35</b>
<b>Kullanıcı 10</b>	4	3	4	4	4	4	26	Sağlıklı	E	<b>23 / 35</b>
<b>Ortalama</b>	<b>4,6 / 5</b> <b>%92</b>	<b>4,5 / 5</b> <b>%90</b>	<b>4,5 / 5</b> <b>%90</b>	<b>4,7 / 5</b> <b>%94</b>	<b>4,9 / 5</b> <b>%98</b>	<b>4,8 / 5</b> <b>%96</b>	<b>28,9</b>	<b>6 Sağlıklı / 4 Rahatsızlık</b>	<b>6 K / 4 E</b>	<b>-</b>

Çizelge 7.7. Likert sorularına kullanıcılar tarafından verilen cevaplar ve kullanıcıların özellikleri

## 7.2.2 Hareketi En İyi Temsil Eden Kare (Frame) Sayısı Etkisi

Hareket Özetleme Tekniği 5.1.3 bölümünde belirtildiği gibi egzersiz hareketleri "Veri Madenciliği Modülü" tarafından özetlenmekteydi. Bu bölümde birbirine benzer birçok (500-1000) çerçeveden oluşan egzersiz hareketi özetlenerek, hareketi en iyi temsil eden çerçevelere dönüştürülerek veri madenciliği algoritmalarına girdi olarak verilmekteydi. Bu bölümde en iyi kare sayısının hareket benzerliği üzerine olan etkisinin sonuçları incelenecektir. En iyi kare sayısı 10 seçilerek elde edilen sonuçlar grup bazlı olarak Çizelge 7.1 ve Çizelge 7.2 tablolarında ve grup bağımsız olarak Çizelge 7.3 tablosunda verilmiştir. En iyi çerçevesi sayısı 20 olarak belirlendiğinde elde edilen sonuçlar ise grup bazlı olarak Çizelge 7.8 ve Çizelge 7.9 tablolarında, grup bağımsız olarak Çizelge 7.10 tablosunda verilmiştir. Bu tablolar birbiriyle kıyaslanarak incelendiğinde, hareketi en iyi temsil eden kare sayısının artması egzersiz hareketinin benzerlik oranındaki doğrulukta direkt artış veya azalışa neden olur gibi bir sonuca varmak olanaksızdır.

	Hareket 1	Hareket 2	Hareket 3	Hareket 4	Hareket 5	Hareket 6	Hareket 7	Yaş	Sağlık	Cinsiyet
<b>Kullanıcı 1</b>	%97,76	%98,46	%96,47	%97,69	%96,93	%99,18	%98,18	18	SLAP Rahatsızlığı	K
<b>Kullanıcı 2</b>	%98,06	%99,35	%91,41	%95,84	%97,98	%92,33	%92,33	44	Diz, bel rahatsızlığı	E
<b>Kullanıcı 3</b>	%93,34	%99,50	%95,95	%98,59	%96,79	%97,38	%97,38	39	Omuz Ağrısı, Boyun Fıtığı	K
<b>Kullanıcı 4</b>	%92,70	%99,21	%79,77	%94,98	%89,79	%97,41	%97,41	21	Sağlıklı	K
<b>Kullanıcı 5</b>	%98,19	%81,49	%52,75	%90,11	%90,49	%96,18	%95,56	27	Sağlıklı	K
<b>Ortalama</b>	<b>%96,01</b>	<b>%95,60</b>	<b>%83,27</b>	<b>%95,44</b>	<b>%94,39</b>	<b>%94,92</b>	<b>%96,49</b>	<b>29,8</b>	<b>2 Sağlıklı / 3 Rahatsız</b>	<b>4 K / 1E</b>

Çizelge 7.8. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 1. Grup (En iyi Kare Sayısı: 20, SVM)

	Hareket 1	Hareket 2	Hareket 3	Hareket 4	Hareket 5	Hareket 6	Hareket 7	Yaş	Sağlık	Cinsiyet
<b>Kullanıcı 1</b>	%96,59	%98,55	%98,27	%51,47	%96,00	%95,15	%99,56	28	Sağlıklı	K
<b>Kullanıcı 2</b>	%97,94	%98,28	%93,67	%97,84	%97,36	%95,04	%94,14	22	Sağlıklı	E
<b>Kullanıcı 3</b>	%74,36	%96,11	%56,26	%97,15	%88,78	%98,42	%96,18	19	Boyun Düzleşmesi	K
<b>Kullanıcı 4</b>	%99,36	%99,46	%76,35	%97,20	%98,51	%81,43	%90,03	45	Sağlıklı	E
<b>Kullanıcı 5</b>	%98,95	%99,66	%92,18	%84,62	%98,72	%96,86	%95,28	26	Sağlıklı	E
<b>Ortalama</b>	<b>%93,44</b>	<b>%98,41</b>	<b>%83,34</b>	<b>%85,65</b>	<b>%95,87</b>	<b>%93,38</b>	<b>%93,38</b>	<b>28</b>	<b>4 Sağlıklı / 1 Rahatsız</b>	<b>2 K / 3 E</b>

Çizelge 7.9. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri - 2. Grup (En iyi Kare Sayısı: 20, SVM)

Örneğin, hareket-5 incelendiğinde Grup-1 tablolar (Çizelge 7.1 ve Çizelge 7.8) incelendiğinde sonuçta %7 civarında başarımların azalması olmaktadır, Grup-2 sonuçları (Çi-

zelge 7.2 ve Çizelge 7.9) kıyaslandığında %3'lük bir başarıml artışı görölmüştür. Benzer şekilde tüm hareketlere bakıldığında da (Çizelge 7.3 ve Çizelge 7.10) başarıml oranında azalma olmaktadır, bu yüzden genelleme yapmak güçtür. Diğer hareketlerde incelendiğinde en iyi kare sayısının etkisini genellemek mümkün değildir bu yüzden daha fazla sayıda ve veri seti ile bu sayı analiz edilerek başka bir çalışmada bulunabilir. Sonuç olarak, ViTES uygulaması kapsamında "hareketi en iyi temsil eden kare" sayısı, hız, CPU, RAM ve ağ trafiği gibi faktörler göz önünde bulundurularak küçük tutulmaya çalışılmıştır. Hareket tanıma başarımlının da yüksek olması sebebiyle bu sayı 10 olarak belirlenmiştir.

	Hareket 1	Hareket 2	Hareket 3	Hareket 4	Hareket 5	Hareket 6	Hareket 7	Yaş	Sağlık	Cinsiyet
<b>Kullanıcı 1</b>	%97,76	%98,46	%96,47	%97,69	%96,93	%99,18	%99,18	18	SLAP Rahatsızlığı	K
<b>Kullanıcı 2</b>	%98,06	%99,35	%91,41	%95,84	%97,98	%92,33	%92,33	44	Diz, bel rahatsızlığı	E
<b>Kullanıcı 3</b>	%93,34	%99,50	%95,95	%98,59	%96,79	%97,38	%97,38	39	Omuz Ağrısı, Boyun Fıtığı	K
<b>Kullanıcı 4</b>	%92,70	%99,21	%79,77	%94,98	%89,79	%97,41	%96,18	21	Sağlıklı	K
<b>Kullanıcı 5</b>	%98,19	%81,49	%52,75	%90,11	%90,49	%96,18	%95,56	27	Sağlıklı	K
<b>Kullanıcı 6</b>	%96,59	%98,55	%98,27	%51,47	%96,00	%95,15	%99,56	28	Sağlıklı	K
<b>Kullanıcı 7</b>	%97,94	%98,28	%93,67	%97,84	%97,36	%95,04	%94,14	22	Sağlıklı	E
<b>Kullanıcı 8</b>	%74,36	%96,11	%56,26	%97,15	%88,78	%98,42	%96,18	19	Boyun Düzleşmesi	K
<b>Kullanıcı 9</b>	%99,36	%99,46	%76,35	%97,20	%98,51	%81,43	%90,03	45	Sağlıklı	E
<b>Kullanıcı 10</b>	%98,95	%99,66	%92,18	%84,62	%98,72	%96,86	%95,28	26	Sağlıklı	E
<b>Ortalama</b>	<b>94,72</b>	<b>97,00</b>	<b>83,30</b>	<b>90,54</b>	<b>95,13</b>	<b>94,93</b>	<b>96,62</b>	<b>28,9</b>	<b>6 Sağlıklı / 4 Rahatsızlık</b>	<b>6 K / 4 E</b>

Çizelge 7.10. Fizyoterapi Bölümündeki Kullanıcıların Hareket Yüzdeleri (En iyi Kare Sayısı: 20, SVM)

## 7.3 Mimarinin Oluşturulması Konusunda Sonuçlar

### 7.3.1 1. Mimari Seçimi

Tezimizin başlangıç aşamalarında veri madenciliği için "MATLAB 2016a" kullanılmaktaydı. Veri okuma işlemleri çok zaman almaktaydı. "Python" dili ile bu modülü geliştirmeyle kıyaslandığında daha fazla zaman harcanmaktaydı. Bu geliştirme aşamasında eksi olduğu için "MATLAB"dan vazgeçilmiştir. MATLAB ile üretilen veri madenciliği modelinin istemci uygulama üzerinden üretilen egzersiz hareket verisine hangi hareketin ne doğrulukta yapıldığı sonucunu dönmesi gerekmektedir. Bu sorun "MATLAB" kodunun "C#" koduna dönüştürülerek istemci (Unity) uygulaması içerisinde çağrılmasıyla (CLI çağrısı) çözülmüştür; ancak bu gerçek zamanlı bir çözüm sunmak için çok yavaş

kalmaktaydı. Bu nedenle bu mimari çözümden vazgeçilmiştir.

### **7.3.2 2. Mimari Seçimi**

İkinci mimari seçiminde istemci uygulama içerisinde "CLI" çağrısı yapmak yerine istemci - sunucu mimariye geçiş yapılmıştır. Sunucu tarafında Java teknolojileri ve Spring Boot uygulama çatısı seçilmiştir. Daha sonra istemci uygulama üzerinden REST bir çağrı ile veri gönderimi sağlanacak ve sunucu uygulama bu cevaba dönüş yapacaktır. Sunucu tarafında "MATLAB" tarafından üretilen kod Java'ya dönüştürülüp, Spring Boot sunucu uygulamasına dahil edilmiştir. İstemci tarafından yapılan bir istek sunucu tarafından 50 saniye civarında sonuç üretebilmiştir. Bunun nedeni olarak Java uygulamasında her defasında "MATLAB Runtime Environment"ın başlama süresi, isteğe cevap dönülmesi süresini uzatmaktadır. Bu yüzden bu mimari yaklaşım terk edilmiştir.

### **7.3.3 3. Mimari Seçimi**

Bu mimari seçiminde de istemci - sunucu mimari yapısı kullanılmıştır. "MATLAB" ile sınıflandırma işlemleri yerine "Python" dili ve "sklearn" kütüphaneleri kullanılarak sunucu uygulama "REST" olarak cevap verecek şekilde tasarlanmıştır. Daha sonra istemci JSON veriyi POST istek olarak "Python" sunucusuna iletmıştır ve cevap 5 saniye civarında dönüşmüştür; ancak sürenin hale gerçek zamanlı bir sistem için geçerli olmamasından dolayı bu mimaride iyileştirme yapılmıştır. İstemci uygulama üzerinde ve sunucu uygulama üzerinde JSON dönüşümü yapmak yerine ham veri gönderimi sağlanmıştır ve dönüşüm maliyetleri düşürülmüştür. Bu sayede istemci sunucu arası iletişim süresi 0.5 milisaniyeyi geçmeyecek şekilde optimize edilmiştir.

## **7.4 Sonuç**

Tezimizin çıktılarında biri olarak Hacetepe-Omuz veri setleri oluşturulmuştur. Bu veri setleri Fizyoterapi ve Rehabilitasyon omuz hareketleri alanındaki RGB-D veri eksikliğinin önüne geçecektir ve omuz fizyoterapisi alanında veri madenciliği çalışmalarının önünün açacaktır. Bu veri setlerinde yer alan hareketler, fizyoterapistler tarafından Rehabilitasyon seanslarında ve hasta ev ödevlerinde aktif olarak kullanılmaktadır. Ev ödevi süresinde hastanın fizyoterapistten geri bildirim alma şansı bulunmamaktadır, tezimiz

kapsamında geliştirilen ViTES sistemi ile kullanıcılar ev fizyoterapisinde hareketlerin doğruluğu hakkında geri bildirim alabilmektedir ve sağlanan sanal ortam sayesinde fizyoterapi seanslarına olan bağlılıkları artmaktadır (Bu konudaki hasta yorumları Likert çalışmasıyla verilmiştir Çizelge 7.7). ViTES uygulaması fizyoterapist bakış açısından bakıldığında, hastanın ev ödevi fizyoterapi sürecinin doğru işletilmesi konusuna yardımcı olmaktadır. Hastanın verilen hareketi ne doğrulukla, kaç tekrarda ve toplamda ne kadar süre harcadığını gözlemlemekte ve hastaya özgü bir tedavi programı hazırlayabilmektedir. Tezimiz kapsamında gerçek zamanlı bir sistem geliştirebilmek amacıyla, bir çok kareden (frame) oluşan egzersiz hareketlerinin daha az kare ile temsil ederek (Hareket Özetleme Tekniği Şekil 5.1), veri madenciliği sınıflandırıcı modülünün hızlı bir şekilde cevap dönmesi sağlanmıştır. Buna ek olarak istemci uygulama ile sunucu uygulaması arasında egzersiz verinin iletilmesi, işlenmesi konusunda birçok mimari yaklaşım denenmiş ve nihai olarak en fazla 0.5 ms. süresince egzersiz hareketinin istemci uygulamadan sunucuya iletimi, egzersiz hareketinin özetlenmesi, sınıflandırılması ve tekrar istemci uygulamaya sonucun iletilmesi gibi süreçler sağlanmıştır. Veri madenciliği sınıflandırıcı modelleri sırasıyla doğruluk metriği başarımlarıyla Destek Vektör Makineleri (0.9857), Kalibre Edilmiş Destek Vektör Makineleri (0.9714), K-En Yakın Komşuluğu (0.9428), Karar Ağaçları (0.7714), MLP (0.9857) ve Topluluk Öğrenmesi (0.9857) sınıflandırıcılarıyla modellenmiştir. Buna ek olarak Hacettepe Üniversitesi Fizyoterapi ve Rehabilitasyon Bölümü'nde fizyoterapistler tarafından seçilmiş 10 kişinin katılımıyla Sanal Egzersiz Sistemi (ViTES) test edilmiştir. Egzersiz hareketlerini bilmeyen bu kullanıcılar iki gruba ayrılıp ilk gruba fizyoterapistler tarafından eğitim verilip, ikinci gruba ise ViTES uygulaması üzerinden eğitim verilip egzersiz hareketlerini benzerlik başarımları gözlemlenmiştir. Bu test sonucunda 7 hareketin 6'sında fizyoterapistten eğitim alan grup hareketler bazında en fazla %6 oranında daha fazla başarıma sahiptir bir hareketin başarımlarında ise ViTES uygulaması fizyoterapist eğitiminin önündedir (Çizelge 7.1 ve Çizelge 7.2). Bu iki grubun ortak sonuçları gerçek zamanlı bu sistemin başarımları hakkında bilgiler vermektedir Çizelge 7.3. Hareket bazlı bu başarımlar incelendiğinde Hareket-1(%95,25), Hareket-2(%97,82), Hareket-3 (%80,02), Hareket-4 (%86,33), Hareket-5 (%94,16) ve Hareket-7(%94,99) ViTES sisteminin ev ödevi fizyoterapi sürecinde veya fizyoterapist sayısı azlığı olan kliniklerde kullanımı gelecek vaad etmektedir. Son olarak ViTES sisteminin kullanıcılar tarafından değerlendirilmesi sağlamak amacıyla Likert

alıřması yapılmıřtır ve kullanıcılar tarafından sistemiz %96 oranında beęenilmiş, kullanıcıların tamamı (%100) tarafından ViTES sistemini ev ödevi fizyoterapisini kullanmak istemişleridir. Bunun yanı sıra kullanıcılar, fizyoterapi ve rehabilitasyon gerektiren rahatsızlıkların çözümlüne ViTES sisteminin %96 oranında katkı yapacağını düşünmektedir.

## KAYNAKLAR

- [1] Green, S., Buchbinder, R., Glazier, R., et al., *Systematic review of randomised controlled trials of interventions for painful shoulder: selection, criteria, outcome assessment, and efficacy*, British Medical Journal 316, **1998**, pp. 354-360.
- [2] Rekola, K.E., Keinanen-Kiukaanniemi, S., Takala, J., *Use of primary health services in sparsely populated country districts by patients with musculoskeletal symptoms: consultations with a physician*, Journal of Epidemiology & Community Health 47, **1993**, pp. 153-157.
- [3] Ogilvie-Harris, D.J., Biggs, J., Fitsialos, P., et al., *The resistant frozen shoulder*, Clinical Orthopaedics and Related Research 319, **1995**, pp. 238-242.
- [4] Rizk, T.E., Gavant, M.L., & Pinals, R.S., *Treatment of adhesive capsulitis (frozen shoulder) with arthrographic capsular distension and rupture*, Physical Medicine and Rehabilitation 75, **1994**, pp. 803-807.
- [5] I. Ar and Y. S. Akgul, *A monitoring system for home-based physiotherapy exercises*, in Computer and Information Sciences III, **2013**, pp. 487-494.
- [6] J. Aggarwal and M. Ryoo, *Human activity analysis: A*, ACM Comput. Surv., vol. 43, no. 3, April **2011**, pp. 16:1-16:43.
- [7] A. Koller-Hodac, D. Leonardo, S. Walpen, and D. Felder, *A novel robotic device for knee rehabilitation improved physical therapy through automated process*, in IEEE/RAS-EMBS International Conference on Biomedical Robotics and Biomechatronics, Tokyo, Japan, pp. 820-824, **2010**.
- [8] P. M. van Vliet and G. Wulf, *Extrinsic feedback for motor learning after stroke: What is the evidence?*, Disability and Rehabilitation 28, Volume 28, no. 13-14, **2006**, pp. 831-84.
- [9] H. Kim, S. Lee, Y. Kim, S. Lee, D. Lee, J. Ju, and H. Myung, *Weighted joint-based human behavior recognition algorithm using only depth information for low-cost intelligent video-surveillance system*, Expert Systems with Applications, vol. 45, **2016**, pp. 131-141.
- [10] Carifio, J. and Perla, R. *Resolving the 50 Year Debate around Using and Misusing Likert Scales*, Medical Education **2008**, 42, 1150-1152.
- [11] L. D Souza, I. Pathirana, D. Mcmeel, R. Amor, *Kinect to Architecture*, **2011**.
- [12] M. Liu and H. Liu, *Depth context: a new descriptor for human activity recognition by using sole depth sequences*, Neurocomputing, vol. 175, **2016**, pp. 747-758.
- [13] A.-A. Liu, N. Xu, Y.-T. Su, H. Lin, T. Hao, and Z.-X. Yang, *Single/multi-view human action recognition via regularized multi-tasklearning*, Neurocomputing, vol. 151, **2015**, pp. 544-553.

- [14] H. Eum, C. Yoon, H. Lee, and M. Park, *Continuous human action recognition using depth-mhi-hog and a spotter model*, *Sensors*, vol. 15, no. 3, **2015**, pp. 5197-5227.
- [15] N. Li, Y. Dai, R. Wang, and Y. Shao, *Study on action recognition based on kinect and its application in rehabilitation training*, in *Big Data and Cloud Computing (BDCloud)*, 2015 IEEE Fifth International Conference on, **2015**, pp. 265-269.
- [16] F. Jiang, S. Zhang, S. Wu, Y. Gao, and D. Zhao, *Multi-layered gesture recognition with kinect*, *The Journal of Machine Learning Research*, vol. 16, no. 1, **2015**, pp. 227-254.
- [17] D. Wenwen, L. Kai, X. Fu, C. Fei, *Profile HMMs for Skeleton-based Human Action Recognition*, *Signal Processing: Image Communication* 42, **2016**.
- [18] G. Zhu, L. Zhang, P. Shen, and J. Song, *An online continuous human action recognition algorithm based on the kinect sensor*, *Sensors*, vol. 16, no. 2, **2016**, pp. 161.
- [19] G. Zhu, L.Zhang, P. Shen, *Human action recognition using multi-layer codebooks of key poses and atomic motions*, *Image Communication archive*, Volume 42, Issue C, March **2016**, pp 19-30.
- [20] S. Boubou and E. Suzuki, *Classifying actions based on histogram of oriented velocity vectors*, *Journal of Intelligent Information Systems*, vol. 44, no. 1, **2015**, pp. 49-65.
- [21] J. Ding and C.-W. Chang, *Feature design scheme for kinect-based dtw human gesture recognition*, *Multimedia Tools and Applications archive*, Volume 75, Issue 16, August **2016**, pp. 9669-9684.
- [22] Ing-Jr Ding, Che-Wei Chang, *An eigenspace-based method with a user adaptation scheme for human gesture recognition by using Kinect 3D data*, *Applied Mathematical Modelling*, Volume 39, Issue 19, 2015, pp. 5769-5777.
- [23] X. Chen and M. Koskela, *Skeleton-based action recognition with extreme learning machines*, *Neurocomputing archive*, Volume 149, Issue PA, February **2015**], pp. 387-396
- [24] Ju Sun, Xiao Wu, Shuicheng Yan, L. Cheong, T. Chua and Jintao Li, *Hierarchical spatio-temporal context modeling for action recognition*, 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, **2009**, pp. 2004-2011.
- [25] L. Cao, Z. Liu and T. S. Huang, *Cross-dataset action detection*, 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Francisco, CA, **2010**, pp. 1998-2005.
- [26] A. Kovashka and K. Grauman, *Learning a hierarchy of discriminative space-time neighborhood features for human action recognition*, 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Francisco, CA, **2010**, pp. 2046-2053.



- [27] J. C. Niebles, C. W. Chen, and L. Fei-Fei, *Modeling temporal structure of decomposable motion segments for activity classification*, in Computer Vision - ECCV 2010, 11th European Conference on Computer Vision, Heraklion, Crete, Greece, September 5-11, **2010**, Proceedings, Part II.
- [28] Laptev and Lindeberg, *Space-time interest points*, Proceedings Ninth IEEE International Conference on Computer Vision, Nice, France, **2003**, pp. 432-439 vol.1.
- [29] F. Lv and R. Nevatia, *Single View Human Action Recognition using Key Pose Matching and Viterbi Path Searching*, 2007 IEEE Conference on Computer Vision and Pattern Recognition, Minneapolis, MN, **2007**, pp. 1-8.
- [30] D. Weinland and E. Boyer, *Action recognition using exemplar-based embedding*, 2008 IEEE Conference on Computer Vision and Pattern Recognition, Anchorage, AK, **2008**, pp. 1-7.
- [31] W. Li, Z. Zhang, and Z. Liu, *Expandable data-driven graphical modeling of human actions based on salient postures*, Circuits and Systems for Video Technology, vol. 18, no. 11, **2008**.
- [32] D. Chen, S. Shih and H. M. Liao, *Human Action Recognition Using 2-D Spatio-Temporal Templates*, 2007 IEEE International Conference on Multimedia and Expo, Beijing, **2007**, pp. 667-670.
- [33] A. F. Bobick and J. W. Davis, *The recognition of human movement using temporal templates*, in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 23, no. 3, pp. 257-267, March **2001**.
- [34] L. Kovar, *Automated extraction and parameterization of motions in large data sets*, ACM Transactions on Graphics (TOG) TOG Homepage, Volume 23, Issue 3, August **2004**, pp. 559-568.
- [35] K. Forbes and E. Fiu, *An efficient search algorithm for motion data using weighted pca*, in SCA '05 Proceedings of the 2005 ACM SIGGRAPH/Eurographics symposium on Computer animation , **2005**, pp. 67-76.
- [36] W. Li, Z. Zhang and Z. Liu, *Action recognition based on a bag of 3D points*, 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Workshops, San Francisco, CA, **2010**, pp. 9-14.
- [37] M. Muller and T. R.  $\frac{1}{2}$  oder, *Motion templates for automatic classification and retrieval of motion capture data*, in SCA '06 Proceedings of the 2006 ACM SIGGRAPH/Eurographics symposium on Computer animation, **2006**, pp. 137-146.
- [38] M. Muller, A. Baak, and H.-P. Seidel, *Efficient and robust annotation of motion capture data*, in Eurographics/ ACM SIGGRAPH Symposium on Computer Animation, **2009**, pp. 17-26.

- [39] J. M. Raptis, D. Kirovski, and H. Hoppe, *Real-time classification of dance gestures from skeleton animation*, Proceeding SCA '11 Proceedings of the 2011 ACM SIGGRAPH/Eurographics Symposium on Computer Animation, **2011**, pp. 147-156.
- [40] J. W. Davis and A. Tyagi, *Minimal-latency human action recognition using reliable-inference*, Image and Vision Computing Archive, Volume 24, Issue 5, May, **2006**, pp. 455-472.
- [41] M. Reyes, G. Domínguez and S. Escalera, *Featureweighting in dynamic time-warping for gesture recognition in depth data*, 2011 IEEE International Conference on Computer Vision Workshops (ICCV Workshops), Barcelona, **2011**, pp. 1182-1188.
- [42] F. Deboeverie, S. Roegiers, G. Allebosch, P. Veelaert and W. Philips, *Human gesture classification by brute-force machine learning for exergaming in physiotherapy*, 2016 IEEE Conference on Computational Intelligence and Games (CIG), Santorini, **2016**, pp. 1-7.
- [43] R. Clark, Y.-H. Pua, K. Fortin, C. Ritchie, K. Webster, L. Denehy, and A. Bryant, *Validity of the microsoft kinect for assessment of postural control*, Gait and Posture, vol. 36, no. 3, July **2012**, pp. 372-377.
- [44] S. Bhattacharya, B. Czejdo, and N. Perez, *Gesture classification with machine learning using kinect sensor data*, in Emerging Applications of Information Technology, December **2012**, pp. 348-351.
- [45] O. Patsadu, C. Nukoolkit and B. Watanapa, *Human gesture recognition using Kinect camera*, 2012 Ninth International Conference on Computer Science and Software Engineering (JCSSE), Bangkok, **2012**, pp. 28-32.
- [46] J. Shotton et al., *Real-time human pose recognition in parts from single depth images*, in CVPR 2011, Providence, RI, **2011**, pp. 1297-1304.
- [47] Ayoade M., Baillie L., *A novel knee rehabilitation system for the home*, In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '14). ACM, New York, NY, USA, **2014**, 2521-2530.
- [48] Swamy Ananthanarayan, Miranda Sheh, Alice Chien, Halley Profita, and Katie A. Siek., *Designing wearable interfaces for knee rehabilitation*, In Proceedings of the 8th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth '14). ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), ICST, Brussels, Belgium, **2014**, pp. 101-108.
- [49] Merce Piqueras, Ester Marco, Maria Coll, Ferran Escalada, Alex Ballester, Carme Cinca, Roser Martínez, Josep Muniesa., *Effectiveness of an interactive virtual telerehabilitation system in patients after total knee arthroplasty: A randomized*

*controlled trial*, Journal of rehabilitation medicine : official journal of the UEMS European Board of Physical and Rehabilitation Medicine. 45. 10.2340/16501977-1119, **2013**.

- [50] J. C. Kimel, *Thera-Network: a wearable computing network to motivate exercise in patients undergoing physical therapy*, 25th IEEE International Conference on Distributed Computing Systems Workshops, **2005**, pp. 491-495.
- [51] L. E. Sucar, F. Orihuela-Espina, R. L. Velazquez, D. J. Reinkensmeyer, R. Leder and J. Hernández-Franco, *Gesture Therapy: An Upper Limb Virtual Reality-Based Motor Rehabilitation Platform*, in IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 22, no. 3, May **2014**, pp. 634-643.
- [52] D. Anton, A. Goni, A. Illarramendi, J. J. Torres-Unda and J. Seco, *KiReS: A Kinect-based telerehabilitation system*, 2013 IEEE 15th International Conference on e-Health Networking, Applications and Services (Healthcom 2013), Lisbon, **2013**, pp. 444-448.
- [53] Statistical Analysis System Institute, *SAS 1998 Annual Report*, p.51, **2012**. [Online]. Available: <https://www.sasgroup.net/en/sas-annual-report-1998/>. [Accessed: Jan. 30, 2018].
- [54] Sidik, M., Sunar, M., Ismail, I., Mokhtar, M., *A Study on Natural Interaction for Human Body Motion using Depth Image Data*, Workshop on Digital. Media and Digital Content Management, UTM ViCubeLab, Department of Computer Graphics and Multimedia Faculty of Computer Science and Information System, Universiti Teknologi Malaysia, 26, 97-102, Malaysia, **2011**.
- [55] Kanatlı, U., *Omuz Hastalıkları ve Artroskopisi*, İzmir, US Akademi, **2017**.
- [56] Tan, P., Steinbach M., Kumar V., *Introduction to Data Mining*, Pearson, **2005**.
- [57] Kodratoff Y., *Introduction to Machine Learning* Morgan Kaufmann Publishing, **2014**.
- [58] Kittipong C., Chujai, Pasapichi C. *An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm*, Proceeding of the 3rd International Conference on Industrial Application Engineering, **2015**.
- [59] Gersho, A., Gray, R.M., *Vector Quantization and Signal Compression*, Kluwer Academic Publishers Norwell, USA, **1991**, pp. 738.
- [60] Y. Linde, A. Buzo and R. Gray, *An Algorithm for Vector Quantizer Design*, in IEEE Transactions on Communications, vol. 28, no. 1, January **1980**, pp. 84-95.
- [61] K. Y. Akın, *Veri Madenciliğinde Kümeleme Algoritmaları ve Kümeleme Analizi*, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul, 164s, **2008**.

- [62] S. Gündüz, *Uzaklık Fonksiyonlarının Çok Boyutlu Ölçekleme Algoritmalarındaki Etkinliğinin İncelenmesi ve Uygulamalar*, Çukurova Üniversitesi, Adana, Türkiye, **2011**.
- [63] Vapnik, V.N., 2010, *The Nature of Statistical Learning Theory*, Springer-Verlag, New York, **2010**.
- [64] E.Akalın, Ö.F. Şendur, S.Gülbahar, *Ortopedik Rehabilitasyon El Kitabı*, Akademi Yayınevi, **2016**.
- [65] M. Beyazova, Y. Kutsal, *Fizyoterapi Tıp ve Rehabilitasyon*, Güneş Tıp Kitapevleri, **2016**.
- [66] Ahmet Kulduk et al. *Omuz Hastalıkları ve Artroskopisi*, US Akademi, **2017**.
- [67] S. R. Safavian and D. Landgrebe, *A survey of decision tree classifier methodology*, in IEEE Transactions on Systems, Man, and Cybernetics, vol. 21, no. 3, pp. 660-674, May-June **1991**. doi: 10.1109/21.97458
- [68] B.Demir, *Veri Madenciliğinde Chaid Algoritmasının Sosyal Güvenlik Kurumu Veri Tabanına Uygulanması*, Gazi Üniversitesi, Ankara, Türkiye, **2010**.
- [69] SPSS 2001 **2001**.
- [70] Anil K. Ghosh, *On optimum choice of k in nearest neighbor classification*, Comput. Stat. Data Anal. 50, 11 (July **2006**), 3113-3123.
- [71] Andrew Ng, *Support Vector Machines*, Stanford University, Machine Learning CS229, <http://cs229.stanford.edu/materials.html>, (Nisan **2017**).
- [72] Christopher J.C. Burges, *A Tutorial on Support Vector Machines for Pattern Recognition*, Kluwer academic Publishers, Boston, Data Mining and Knowledge Discovery 2, **1998**, 121-167.
- [73] Fernando Cassola, Leonel Morgado, Fausto de Carvalho, Hugo Paredes, Benjamim Fonseca, and Paulo Martins, *Online-gym: a 3d virtual gymnasium using kinect interaction*, Procedia Technology 13 **2014**, 130-138.
- [74] Yao-Jen Chang, Shu-Fang Chen, and Jun-Da Huang, *A kinect-based system for physical rehabilitation: A pilot study for young adults with motor disabilities*, Research in developmental disabilities 32 **2011**, no. 6, 2566-2570.
- [75] Yao-Jen Chang, Wen-Ying Han, and Yu-Chi Tsai, *A kinect-based upper limb rehabilitation system to assist people with cerebral palsy*, Research in developmental disabilities 34 **2013**, no. 11, 3654-3659.
- [76] Alana Elza Fontes Da Gama, Thiago Menezes Chaves, Lucas Silva Figueiredo, Adriana Baltar, Ma Meng, Nassir Navab, Veronica Teichrieb, and Pascal Fallavolita, *Mirrabilitation: A clinically-related gesture recognition interactive tool for an ar rehabilitation system*, Computer methods and programs in biomedicine 135 **2016**, 105-114.

- [77] Aijse W de Vries, Gert Faber, Ilse Jonkers, Jaap H Van Dieen, and Sabine MP Verschueren, *Virtual reality balance training for elderly: Similar skiing games elicit different challenges in balance training*, *Gait & posture* 59 **2018**, 111-116.
- [78] Michele Pirovano, Elif Surer, Renato Mainetti, Pier Luca Lanzi, and N Alberto Borghese, *Exergaming and rehabilitation: A methodology for the design of effective and safe therapeutic exergames*, *Entertainment Computing* 14 (**2016**), 55-65.
- [79] Amanda E Staiano and Sandra L Calvert, *The promise of exergames as tools to measure physical health*, *Entertainment Computing* 2 **2011**, no. 1, 17-21.
- [80] Chuan-Jun Su, Chang-Yu Chiang, and Jing-Yan Huang, *Kinect-enabled home-based rehabilitation system using dynamic time warping and fuzzy logic*, *Applied Soft Computing* 22 **2014**, 652-666.
- [81] H Tannous, D Istrate, MC Ho Ba Tho, and TT Dao, *Feasibility study of a serious game based on kinect system for functional rehabilitation of the lower limbs*, *European Research in Telemedicine/La Recherche Européenne en Télémedecine* 5 **2016**, no. 3, 97-104.
- [82] M Van Diest, J Stegenga, HJ Wörtche, Gijsbertus Jacob Verkerke, K Postema, and CJC Lamothe, *Exergames for unsupervised balance training at home: a pilot study in healthy older adults*, *Gait & posture* 44 **2016**, 161-167.



HACETTEPE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
YÜKSEK LİSANS/~~DOKTORA~~ TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 18/09/2019

Tez Başlığı / Konusu: Omuz Egzersizlerinin RGB-D Verisi Kullanılarak Gerçek Zamanlı Kestirimi İçin Sanal Egzersiz Sistemi

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 96 sayfalık kısmına ilişkin, 18/09/2019 tarihinde ~~sağım~~/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %7'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/~~dâhil~~
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

18.09.2019

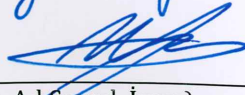
  
Tarih ve İmza

Adı Soyadı: Volkan Ulutaş  
Öğrenci No: N14121758  
Anabilim Dalı: Bilgisayar Mühendisliği  
Programı: Yüksek Lisans  
Statüsü:  Y.Lisans  Doktora  Bütünleşik Dr.

**DANIŞMAN ONAYI**

UYGUNDUR.

Dr. Öğr. Üyesi Yürek Celibekcan



(Unvan, Ad Soyad, İmza)

## ÖZGEÇMİŞ

### Kimlik Bilgileri

Adı Soyadı : Volkan ULUTAŞ

Doğum Yeri : Kayseri

Medeni Hali : Bekar

Yazışma Adresi : Keklikpınarı Mah. Turtaş Sit. A2 Blok D. No:12 B. No:10 Çankaya / ANKARA

Telefon : +(90) 532 342 33 27

Elektronik Posta : volkanulutas@hacettepe.edu.tr

Yabancı Dili : İngilizce

### Eğitim Durumu

Lisans : Çankaya Üniversitesi Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 2013, ANKARA.

Lisans : Anadolu Üniversitesi İktisadi İdari İlimler Fakültesi, İşletme Bölümü, 2016, ES-KİŞEHİR.

Yüksek Lisans : Hacettepe Üniversitesi Fen Bilimleri Fakültesi, Bilgisayar Mühendisi Bölümü, 2019, ANKARA.

### İş Deneyimi

Şubat 2013 - Temmuz 2017 Kıdemli Yazılım Mühendisi, MilSOFT Yazılım Teknolojileri A.Ş. , ANKARA.

Temmuz 2017 - ... Uzman Yazılım Mühendisi, Türk Havacılık Uzay Sanayi A.Ş. (TUSAŞ) - Uzay Sistemleri Başkanlığı, ANKARA.