

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



DERİNLİK KAMERASI İLE YAŞLILARDA DÜŞME TESPİTİ

Muzaffer ASLAN

Doktora Tezi

Anabilim Dalı: Elektrik Elektronik Mühendisliği

Programı: Devreler ve Sistemler

Danışman: Doç. Dr. Melih Cevdet İNCE

HAZİRAN 2016

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİNLİK KAMERASI İLE YAŞLILARDA DÜŞME TESPİTİ

DOKTORA TEZİ

Muzaffer ASLAN
(112113202)

Tezin Enstitüye Verildiği Tarih:28.06.2016

Tezin Savunulduğu Tarih:21.07.2016

Tez Danışmanı : Doç. Dr. Melih Cevdet İNCE (F.Ü.)

Diğer Jüri Üyeleri : Prof. Dr. Sami EKİCİ (F.Ü.)

Yrd. Doç. Dr. Murat KARABATAK (F.Ü.)

Doç. Dr. Davut HANBAY (İ.Ü.)

Yrd. Doç. Dr. Ömer Faruk ALÇİN (B.Ü.)

HAZİRAN 2016

ÖNSÖZ

Doktora eğitimimin her aşamasında her daim beni destekleyen ve hep yanımda olan sevgili eşim Nurhan ASLAN'a, çocuklarıma ve aileme sabır, hoşgörü ve manevi destekleri için teşekkür ederim.

Danışman hocam Sayın Doç. Dr. Melih Cevdet İNCE'ye tez çalışması boyunca yaptığı katkılardan dolayı teşekkür ederim.

Doktora eğitimine başladığım günden tez çalışmasının hazırlanması ve yazımı sürecinde karşılaştığım her türlü sorunun çözümü için yol gösteren, desteğini esirgemeyen, tecrübelerini benimle paylaşan ve bilimsel katkılarıyla bana değer katan değerli hocam Sayın Prof. Dr. Abdulkadir ŞENGÜR'e sonsuz teşekkür ve şükranlarımı sunarım.

Ayrıca doktora eğitimim süresince sürekli beni motive eden, her konuda desteğini esirgemeyen, ayrıca bilgi ve görüşlerine başvurduğum Yrd. Doç. Dr. Ömer Faruk ALÇİN'e ve tez yazım aşamasında yardımcı olan Yaman AKBULUT, Erdem AKAGÜNDÜZ, Ferhat UÇAR ve Fethi ASLAN'a ayrıca teşekkür ederim.

Bu tezinin, Yaşlılara ve Yaşlılarda Düşme Tespiti konusunda yapılacak olan çalışmalara katkıda bulunmasını dilerim.

Saygılarımla.

Muzaffer ASLAN

ELAZIĞ- 2016

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ	II
İÇİNDEKİLER.....	III
ÖZET	VI
SUMMARY	VII
ŞEKİLLER LİSTESİ	VIII
TABLolar LİSTESİ	X
KISALTMALAR LİSTESİ	XI
SİMGELER LİSTESİ	XII
1. GİRİŞ	1
1.1. Motivasyon	1
1.2. Tezin Amaç ve Kapsamı	3
1.3. Tezin Çıktıları	3
1.4. Tezin Organizasyonu	4
2. LİTERATÜR İNCELEMESİ	6
2.1. Düşme Tespit Sistemi ve Amacı	6
2.2. Düşme Tespit Yöntemleri	8
2.2.1. Giyilebilir Sensör Tabanlı Yöntemler	10
2.2.2. Ortam Duyarlı Sensör Tabanlı Yöntemler	12
2.2.3. Görüntü Tabanlı Yöntemler	13
2.2.3.1. KYM Renkli Kameralar ile Yapılan Düşme Tespit Çalışmaları	13
2.2.3.2. KYM-D Kameralar ile Yapılan Düşme Tespit Çalışmaları	16
3. MATERYAL VE YÖNTEM	19
3.1. Öznitelik Çıkarım Yöntemleri	19
3.1.1. Eğrilik Ölçek Uzayı	19
3.1.2. Yönelim Ölçek Uzayı	25
3.2. Öznitelik Kodlama Yöntemleri	27
3.2.1. Fisher Vektör	28
3.2.2. Kelime Çantası	29
3.3. Sınıflandırma Yöntemleri	31
3.3.1. Destek Vektör Makinası	32
3.3.2. Naïve Bayes Sınıflandırma	35

3.3.3.	k-En Yakın Komşu Algoritması ile Sınıflandırma	36
4.	FUKINECT – DÜŞME VERİ SETİNİN OLUŞTURULMASI	37
4.1.	Giriş.....	37
4.2.	Microsoft Kinect® Kamera.....	37
4.3.	Kinect® Donanım Özellikleri	39
4.3.1.	Kinect® Görmesi	39
4.3.2.	Kinect® Duyması	41
4.3.	Yazılım Geliştirme Kiti.....	43
4.4.	Mevcut Düşme Veri Setleri.....	43
4.4.1.	SDUFALL Veri Seti	43
4.4.2.	EDF Veri Seti.....	44
4.4.3.	OCCU Veri Seti	45
4.4.4.	MultiCam Veri Seti.....	47
4.4.5.	Wiezmann Veri Seti.....	47
4.4.6.	UTKinect-Action Veri Seti	48
4.5.	FUKinect – Fall Veri Seti	48
4.5.1	Deney Alanın Oluşturulması.....	49
4.5.2	Veri Setinin Oluşturulması	50
5.	DERİNLİK VİDEOLARINDA ETKİLİ DÜŞME TESPİTİ İÇİN FISHER VEKTÖR İLE ŞEKİL ÖZELLİKLERİNİN KODLANMASI.....	59
5.1.	Giriş.....	59
5.2.	Önerilen FV Kodlama Yöntemi.....	59
5.3.	Deneyisel Çalışmalar	61
6.	SİLÜET YÖNELİM HACMİ İLE DERİNLİK VİDEOLARINDA ETKİN DÜŞME TESPİTİ	69
6.1.	Giriş.....	69
6.2.	Önerilen SYH Yöntemi.....	69
6.3.	Deneyisel Çalışmalar	72
7.	EKLEM TABANLI ETKİLİ DÜŞME TESPİTİ.....	79
7.1.	Giriş.....	79
7.2.	Önerilen Eklem Tabanlı Düşme Tespit Yöntemi.....	79
7.3.	Deneyisel Çalışmalar	82
8.	SONUÇLAR VE DEĞERLENDİRME	89

8.1.	Sonuçların Değerlendirilmesi	89
8.2.	Öneriler	91
	KAYNAKLAR	92
	ÖZGEÇMİŞ.....	104



ÖZET

Yaşlılıkta insan vücudundaki biyolojik ve fizyolojik değişiklikler ile birlikte yaşlılar sıkça düşmeye maruz kalmaktadırlar. Bu durum yaşlıların yaralanmalarına neden olmaktadır. Bu yaralanmaların tedavi süreçleri uzamakta ve yaşlıların yaşam kalitelerini de olumsuz etkilemektedir. Ayrıca yaralanmalar ülkelerin sağlık harcamalarında önemli oranda artışa neden olmaktadır. Bu sorunların giderilmesi için yaşlı düşmelerinin tespiti büyük önem arz etmektedir.

Bu amaçla tez çalışmasında, derinlik kamerası ile yaşlılarda düşme tespiti için üç farklı yöntem önerilmiş ve bir veri seti oluşturulmuştur;

1. Derinlik görüntülerinden düşme tespitinin yapılabilmesini sağlayacak hareket ve duruş tabanlı şekil özniteliklerini tanımlayabilmek için Silüet Yönelim Hacim (SYH) öznitelik çıkarım yöntemi önerilmiştir. SDU-Fall veri seti ile gerçekleştirilen uygulamalarda düşme tespitinde %91,89 ve eylem tanımda %89,63 oranında başarımlar sağlanmıştır.
2. Derinlik görüntülerindeki yürüme, oturma ve uzanma gibi günlük eylemlerden, düşmenin ayırt edilebilirliğini geliştirmek için özniteliklerin kodlanmasında Fisher Vektör (FV) kodlama yöntemi önerilmiştir. Önerilen yöntemin SDUFall veri seti ile gerçekleştirilen uygulamalarda düşme tespitinde %88,83 başarımlar sağlanmıştır.
3. Üç Boyutlu (3B) iskelet eklem verisinin iki ayrı İki Boyutlu (2B) eklem verisine indirgenmesine dayalı öznitelik çıkarım algoritması önerilmiştir. FUKinect-Fall veri seti ile gerçekleştirilen uygulamalarda düşme tespitinde %97,08 başarımlar elde edilmiştir.
4. Kinect kamera kullanılarak 21 deneğin katılımı ile yürüme, eğilme, oturma, çömelme, uzanma ve düşme eylemlerinin simüle edildiği 1008 adet derinlik ve iskelet eklem verilerini içeren FUKinect-Fall veri seti oluşturulmuştur.

Çalışmalarda elde edilen sonuçlar literatürdeki benzer çalışma sonuçları ile karşılaştırılarak önerilen yöntemlerin başarımları gösterilmiştir.

Anahtar Kelimeler: Yaşlı Düşme Tespiti, Eylem Tanıma, Kinect, Eğrilik Ölçek Uzağı, Silüet Yönelim Hacim, Fisher Vektör, Kelime Çantası, k-EYK, Destek Vektör Makinası.

SUMMARY

ELDERLY FALL DETECTION WITH DEPTH CAMERA

The elderly people are frequently exposed to falls due to biological and physiological changes in the human body in older ages. This situation causes injuries in elderly people. Treatment processes are prolonged and adversely affects the life quality of old people. Injuries also cause substantial increase in the country's health expenditures. Detection of the elderly falls is of great importance in order to solve these problems.

For this purpose, in thesis study three different methods are proposed in order to detect fall in elderly people with depth camera and a data set is formed.

1. Silhouette Orientation Volumes (SOV) feature extraction method is proposed in order to define motion and stance based shape features which enable fall detection from depth images. In applications carried out with SDU-Fall data set, 91.89% success rate in fall detection and 89.63% success rate in motion detection are obtained.
2. For coding the features Fisher Vector (FV) coding method is suggested in order to develop the distinguishability of fall from daily activities such as walking, sitting and lying in depth images. In applications performed with the proposed method and SDU-Fall data set, 88.83% success rate in fall detection is achieved.
3. Feature extraction algorithm based on reducing three dimensional (3D) skeleton joint data to two separate two dimensional (2D) skeleton joint data is proposed. 97.08% success in fall detection is obtained in applications with FUKinect-Fall data set.
4. FUKinect-Fall dataset which contains 1008 depth and skeleton joint data that simulate walking, bending, sitting, squatting, lying and falling actions of 21 subjects by using Kinect camera is formed.

By comparing the results obtained from studies with the results of similar studies in the literature, the success of the proposed methods is presented.

Key Words : Elderly Fall Detection, Action Recognition, Kinect, Curvature Scale Space, Silhouette Orientation Volumes, Fisher Vector, Bag of Word, k-NN, Support Vector Machine.

ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 1.1. 2013-2075 yılları arası Türkiye nüfus projeksiyonu	1
Şekil 2.1. Düşme tespit sistemin genel yapısı	7
Şekil 2.3. DTS'lerin genel çalışma yöntemleri	9
Şekil 3.1. Evrişime bağlı olarak eğrideki sıfır geçiş sayısının azalması	24
Şekil 3.2. (a) EÖU görüntüsü ve sınırları, (b) EÖU dairesel kaymaya bağlı olarak yönelimi, (c) EÖU görüntüde gürültü etkisi	24
Şekil 3.3. Bir silüetin yönelim açısına göre dikdörtgensel ve radyal renk dağılımı	27
Şekil 3.4. GKÇ modeli	29
Şekil 3.5. GKÇ'nin oluşturulması	30
Şekil 3.6. KÇ Kodlama örneği; (a) veri kümesi görüntüleri; (b) görüntülerden çıkartılmış tanımlayıcılar; (c) öğrenilmiş sözlükler; (d) frekans histogramları	31
Şekil 3.7. İki sınıflı veriyi ayırabilen hiper düzlemler	32
Şekil 3.8. İki sınıflı verideki alt hiper düzlemler.....	33
Şekil 3.9. İki sınıflı veriyi optimal ayıran hiper düzlem	33
Şekil 3.10. Doğrusal olmayan verilerin doğrusal hiper düzlem ile ayrılması	35
Şekil 4.1. Kinect® kamera görseli	37
Şekil 4.2. Kinect® donanımsal yapısı	38
Şekil 4.3. Kinect® vücut takibi mesafesi	39
Şekil 4.4. Kinect® derinlik görüş açısı	39
Şekil 4.5. İskelet izleme	40
Şekil 4.6. Tam iskelet kipi	40
Şekil 4.7. Oturma kipi	40
Şekil 4.8. Ses girişi	41
Şekil 4.9. Mikrofon dizisi	41
Şekil 4.10. Ses eşiği	42
Şekil 4.11. Yöneltilmeli mikrofon	42
Şekil 4.12. Yüksek ses kaynağı hedefleme	42
Şekil 4.13. SDUFALL veri seti düşme eyleminin silüet görüntüler	44
Şekil 4.14. EDF veri seti düşme eyleminin renkli ve silüet görüntüler	45

Şekil 4.15. Belirli oranlarda engellenmiş düşme eylem örnekleri; (a) İki farklı bakış açılı ve %25 engellenmiş düşme eylem örnekleri, (b) İki farklı bakış açılı ve %50 engellenmiş düşme eylem örnekleri, (c) İki farklı bakış açılı ve %75 engellenmiş düşme eylem örnekleri	47
Şekil 4.16. Veri setindeki bazı eylemlerin KYM ve derinlik görüntüleri	48
Şekil 4.17. Veri seti deney alanı.....	49
Şekil 4.18. Veri seti çalışma alanı	50
Şekil 4.19. Veri seti eylem yönleri	51
Şekil 4.20. Kinect® iskelet yapısı ve eklem numaraları	51
Şekil 4.21. FUKinect-Fall veri setindeki bazı deneklere ait 6 eylemin derinlik görüntüleri; (a) yürüme, (b) eğilme, (c) oturma, (d) çömelme, (e) düşme, (f) uzanma.....	58
Şekil 5.1. FV kodlama ile düşme tespit yöntemi blok diyagramı	60
Şekil 5.2. EÖÜ öznitelikleri çıkarımın gösterimi	61
Şekil 5.3. SDUFall veri setindeki 6 eyleme ait bazı görüntüler	62
Şekil 6.1. SYH ile düşme tespiti ve aşamaları	69
Şekil 6.2. Her bir eyleme ait silüetin kapalı bir eğriye dönüşümü	70
Şekil 6.3. İşlenmiş video çerçeveleri, ilgili SYR görüntüleri ve her bir silüetin 4 MÖÜ seviyelerin elde edilmesi.....	70
Şekil 6.4. 6 sınıf eylemin tanınmasında k-medoid kümeleme hassasiyeti	73
Şekil 6.5. SDU-Fall veri seti eylem örneklerindeki gürültü ve eylemlerin sınıflandırılması	75
Şekil 6.6. Düşme ve düşme olmayan eylemlerin tanınmasında k-medoid kümeleme hassasiyeti	76
Şekil 7.1. Kinect® iskelet eklem yapısı	79
Şekil 7.2. Eklem tabanlı düşme tespit yönteminin aşamaları.....	80
Şekil 7.3. 2B eksen modeli ve bölgeleri.....	81
Şekil 7.4. Ortalama tanımlayıcının zamansal hiyerarşik yapısı	82
Şekil 7.5. FUKinect-Fall veri setindeki eylemlerin iskelet verilerine ait iskelet ve derinlik görüntüleri; (a) Yürüme, (b) Eğilme, (c) Oturma, (d) Çömelme, (e) Uzanma, (f)Düşme	84

TABLÖLAR LİSTESİ

	Sayfa No
Tablo 4.1. eğilme eylemine ait bazı çerçevelerdeki 20 eklem koordinatları	51
Tablo 5.1. Düşme ve düşmenin olmadığı eylem sınıflandırma sonuçları	63
Tablo 5.2. Düşme tespitinde sınıflandırıcıların karşılaştırılması	64
Tablo 5.3. KÇ-DVM yöntemi için karışıklık matrisi (%).....	65
Tablo 5.4. KÇ-AÖM yöntemi için karışıklık matrisi (%).....	65
Tablo 5.5. KÇ-DPSO-AÖM yöntemi için karışıklık matrisi (%)	66
Tablo 5.6. FV-DVM yöntemi için karışıklık matrisi (%)	67
Tablo 5.7. 6 sınıf eylemin sınıflandırmasındaki genel doğruluk	67
Tablo 5.8. MultiCam veri seti ile düşme ve düşme olmayan eylemlerin sınıflandırılması	68
Tablo 6.1. 6 eylemin tanınma başarımlarının karşılaştırılması.....	73
Tablo 6.2. Düşme ve düşmenin olmadığı eylemlerin başarımlarının karşılaştırılması.....	76
Tablo 6.3. 6 sınıf eylemin sınıflandırmasındaki başarımın karşılaştırılması	77
Tablo 6.4. Düşme ve düşme olmayan eylem sınıflandırmasında başarımın karşılaştırılması.....	77
Tablo 6.5. Weizmann veri setinin kullanan yöntemlerin başarımların karşılaştırılması.....	77
Tablo 7.1. k-EYK ile 6 eylemin sınıflandırılma sonuçları (%).....	85
Tablo 7.2. DVM ile 6 eylemin sınıflandırılma sonuçları(%).....	86
Tablo 7.3. k-EYK ile düşme ve düşme olmayan eylemlerin sınıflandırılma sonuçları (%).....	87
Tablo 7.4. DVM ile düşme ve düşme olmayan eylemlerin sınıflandırılma sonuçları (%).....	88
Tablo 7.5. UTKinect-Action veri seti ile yapılan çalışmaların başarımların sonuçları	88

KISALTMALAR LİSTESİ

2B	: İki Boyut
3B	: Üç Boyut
ABD	: Amerika Birleşik Devleti
AGKM	: Adaptif Gauss Karışım Modeli
AÖM	: Aşırı Öğrenme Makinası
DPSO	: Değişken uzunlukta Parçacık Sürü Optimizasyonu
DTS	: Düşme Tespit Sistemi
DVM	: Destek Vektör Makinası
EÖU	: Eğrilik Ölçek Uzayı
FV	: Fisher Vektör
GiÜ	: Grafik İşleme Ünitesi
GKÇ	: Görsel Kelime Çantası
GKM	: Gauss Karışım Modeli
GÖU	: Gauss Ölçek Uzayı
KÇ	: Kelime Çantası
k-EYK	: k-En Yakın Komşu
KYM	: Kırmızı Yeşil Mavi
KYM-D	: Kırmızı Yeşil Mavi-Derinlik
MÖU	: Morfolojik Ölçek Uzayı
ODF	: Olasılık Dağılım Fonksiyonu
SMM	: Saklı Markov Modeli
SYH	: Siluet Yönelim Hacim
SYR	: Siluet Yönelim Resim
YGK	: Yazılım Geliştirme Kiti
YÖU	: Yönelim Ölçek Uzayı
YSA	: Yapay Sinir Ağı
UZŞ	: Uzak Zaman Şekilleri
AK	: Ardışıl Kovaryans
DYUZİN	: Derinlik Yerel Uzak Zamansal İlgili Noktaları
DKBÖ	: Derinlik Kubik Benzerlik Özelliği
SNV	: Süper Normal Vektör

SİMGELER LİSTESİ

r	: Parametrik eğri
$r(u)$	: Eğrinin parametrik fonksiyonu
u	: Konumsal eğri parametresi
s	: Yay uzunluğu
$\dot{r}$	: Normalize parametrik eğri
t	: Eğrinin teğet vektörü
n	: Eğrinin normal vektörü
$\dot{t}$	: Teğet vektörünün birinci türevi
$\dot{n}$	: Normal vektörün birinci türevi
κ	: Eğrinin eğriliği
ϕ	: Teğet ve normal vektör arasındaki açısı
Γ	: Düzleştirilmiş parametrik eğri
$g(u, \sigma)$	: Gauss fonksiyonu
I_c	: EÖU görüntünün sıfır geçiş noktalarındaki çok ölçekli sonuçları
$O(u)$	: Yönelim açıları
$L(u, \sigma)$	: Eğrinin ölçek uzayı
k	: Parametrik eğrinin ölçek parametresi
σ	: Standart sapma
X	: Yerel tanımlayıcılar kümesi
O_s	: Olasılık yoğunluk fonksiyonu
G_λ^x	: Gradyant vektörü
K	: Gradyant çekirdeği
F_λ	: Olasılık yoğunluk fonksiyonu bilgi matrisi
x_i	: Özellik vektörü
y_i	: Sınıf etiketi
H	: Hiper düzlem
w	: Ağırlık vektörü
d	: Uzaklık


ζ	: Gevşeklik değişkeni
C	: Ceza parametresi
E	: Ekleme vektörü
θ	: Bölge açısı
n_b	: Bölge sayısı
α	: Eklemler arasındaki açı
A	: Açı vektörü
D	: Uzaklık vektörü
B	: Bölge vektörü



1. GİRİŞ

1.1. Motivasyon

Günümüzde endüstrileşme ile birlikte sosyal, ekonomik, tıbbi, bilimsel ve teknolojik gelişimler bireylerin yaşam sürelerini arttırmıştır. Bu durumun sonucu olarak son yıllarda, tüm dünya genelinde yaşlı nüfus oranı gittikçe artmıştır [1]. 2013 yılında Birleşmiş Milletler tarafından yayımlanan rapora göre 2050 yılında dünya nüfusunun yaklaşık %11,6'sını (997 milyon kişi) 65 yaş ve üzeri yaşlı nüfusun oluşturması beklenmektedir [2]. Benzer şekilde Türkiye'nin 2013 yılında yaşlı nüfusu yaklaşık 5,9 milyon kişi olmasına rağmen, Şekil 1.1'de görüldüğü üzere 2050 yılında bu değerin 19,5 milyon ve 2075 yılında yaklaşık 25 milyon olacağı öngörülmektedir [3]. Başka bir ifade ile 2075 yılındaki yaşlı nüfusun, bugünkü yaşlı nüfustan 6 kat daha fazla olacağı tahmin edilmektedir [3].



Şekil 1.1. 2013-2075 yılları arası Türkiye nüfus projeksiyonu

Yaşlı nüfusun hızlı bir şekilde artması beraberinde önemli halk sağlığı problemlerine yol açmaktadır. Dünya sağlık örgütü verilerine göre, 65 yaş ve üzeri kişilerin yaklaşık %28-35'nin ve 70 yaş üzerinde olanların ise %32-42'sinin her yıl düştüğü belirtilmektedir [4-6]. Ayrıca ortaya konulan bazı çalışmalarda ise, 65 yaş ve üzeri yalnız yaşayan yaşlıların

%33'nün, bakıma muhtaç olanların %63'ünün her yıl en az bir kez düştüğü belirtilmektedir [5-7]. Düşmeye maruz kalanlar ile yapılan bir deneysel çalışmada düşme olayını takip eden süreçte üçte ikisinin tekrar düştüğü tespit edilmiştir [8]. Yaşlılıkta biyolojik değişiklikler ve güçsüz olma ile birlikte düşme sıklığı da artmaktadır. Bu değişimler yaşlanan toplumlarda düşme ve düşmeye bağlı yaralanma oranlarının yükselmesine yol açmaktadır. Yaşlıların düşme kaynaklı maruz kaldıkları en yaygın yaralanmalar; iç doku hasarları, kemik kırılmaları ve kafa travması şeklindedir [4-8]. İngiltere'de her yıl 65 yaş ve üzeri 250.000 kişinin düşmeden dolayı hastanelerde tedavi gördüğü ve Amerika Birleşik Devletleri'nde (ABD) ise her yıl yaş ortalamaları 79 ve üzeri olan 150.000 ile 200.000 kişi arasındaki yaşlıların düşmeden dolayı kalça kemiğinin kırıldığı belirtilmektedir [9].

Düşme kaynaklı yaralanmalar ülkelerin sağlık harcamalarını da önemli ölçüde arttırmaktadır [8,10-12]. 1997 yılında ABD'de yaşayan yaşlıların düşme kaynaklı yaralanmalardan dolayı doğrudan sağlık harcamalarının toplamda 6,2 milyar dolara ulaştığı belirtilmiştir [13]. Bu sağlık harcamaları 2000 yılında 19 milyar dolara ve 2010 yılında 30 milyar dolara yükselmiştir [14-15]. Düşmeye bağlı yaralanmalarda gereken bakım koşullarının yaşlı topluluğu arasında uygulanan en pahalı 20 tıbbi koşuldan birisi olduğu kabul edilmektedir [8]. Aynı zamanda bu yaralanmalar yaşlıların en önemli ölüm nedenleri olarak da ifade edilmektedir [16]. İstatistiklerde, 79 yaş ve üzeri yaşlıların ölüm sebepleri sıralamasında düşme kaynaklı yaralanmalardan dolayı ölümlerin birinci sırada, tüm yaş gruplarında ise ikinci sırada geldiğini belirtilmektedir [17]. Ayrıca düşme kaynaklı yaralanma sonuçları hem zihinsel hem de fiziksel olarak yaşlılarda büyük hasarlara sebep olmaktadır. Görüldüğü gibi düşme özellikle yaşlılar için önemli risklere neden olmaktadır. Buna bağlı olarak yaşlıların yaşam kalitelerini de olumsuz etkilemektedir.

Bu nedenle düşme kaynaklı, yaşlıların yaşam kalitelerini etkileyen ve yukarıda bahsedilen olumsuzlukların azaltılması, ayrıca ülkelerin sağlık harcamalarını ve yaşlı bakımında çalışan insan kaynağını azaltacak yeni teknolojilere ihtiyaç duyulmaktadır. Yalnız yaşayan yaşlıların düşmeye karşı yaşam kalitelerini artırılabilir, düşme kaynaklı yaşlı sağlık giderlerini ve insan kaynağını azaltabilecek düşme gibi olağan dışı durumları tespit etmek çok önemlidir.

Birçok ülkede hükümetler düşme tespit teknolojisinin geliştirilmesini hızlandırmak için yatırımları arttırmıştır. Singapur Gümüş Sanayi Konferans ve Sergisi kapsamında düzenlenen konferansta araştırmacıların düşme tespitine dayalı çalışmalara odaklanarak

yaşlıların sağlıklarıyla ilgili fikirlerin, ürünlerin ve teknolojilerin destekleneceği belirtilmiştir [18].

ABD’de öğrenci ve öğretim üyelerinden oluşan ve disiplinler arası grupları içeren birçok araştırmacı, yaşlıların bilişsel ve fiziksel değişimlerini dikkate alarak onların ihtiyaçlarını karşılamak amacıyla teknolojileri değerlendirmek, araştırmak ve geliştirmek için birçok araştırma enstitüleri kurmuşlardır. Bunlardan biri de Missouri Üniversitesi’ndeki yaşlı bakım ve rehabilitasyon teknolojileri merkezidir. Bu merkezin bazı önemli projeleri ev ortamındaki yaşlı düşmelerini tespit etmek için kesintisiz araştırmalar yapmak ve düşmelerin risk değerlendirmesi için yürüme analizi ve pasif düşme tespiti üzerine çalışmaktır [19,20].

1.2. Tezin Amaç ve Kapsamı

Bu tez çalışmasının genel amacı, tek derinlik kamerası kullanarak ev ortamı gibi kapalı ortamlarda yaşayan yaşlı düşmelerinin tespiti için yüksek hassasiyetli yeni yöntemler geliştirmektir. Böylece acil çağrı merkezleri ve yaşlı yakınlarına yapılan hatalı bildirimlerin sayısı azaltılarak acil çağrı merkezlerinin gereksiz yere meşgul edilmesinin en az düzeye indirilmesi yönünde katkı sağlanacaktır. Ayrıca düşme kaynaklı yaralanmaların tedavisi için düşme eyleminin nasıl ve hangi yönde gerçekleştiği konusunda klinik bilgilerin de elde edilebilmesine katkı sağlanacaktır. Bu amaçla Kinect® derinlik kamerasından alınan derinlik görüntüleri ve iskelet verileri kullanılarak iki farklı öznitelik çıkarım ve bir kodlama algoritması önerilmiş ve çıkarılan öznitelikler Destek Vektör Makinası (DVM), Naïve Bayes ve k-En Yakın Komşu (k-EYK) sınıflandırıcıları kullanılarak sınıflandırılmıştır. Önerilen bu algoritmalar, aynı veri setlerini kullanan diğer yöntemler ile karşılaştırılmış ve yapılan değerlendirmelerde daha iyi başarımlar elde edildiği görülmüştür. Araştırmacıların kullanımına açılmış sınırlı sayıda veri seti olması nedeni ile tez çalışmasında FUKinect-Fall veri seti oluşturulmuştur.

1.3. Tezin Çıktıları

Tezde yapılan çalışmalar sonucunda ulaşılan hedefler şunlardır;

- Kişi gizliliğini ve mahremiyeti koruyan, düşme tespitinde yüksek başarıma sahip üç ayrı yöntem geliştirilmiştir.

- Araştırmacıların kullanımına açılacak 19-72 yaş aralığında, farklı fiziksel özelliklere sahip 21 denek ile oluşturulmuş düşme ve günlük eylemleri içeren ve her bir eylemin farklı kamera bakış açısı ile 8'er kez tekrar edildiği veri seti oluşturulmuştur.

1.4. Tezin Organizasyonu

Bu doktora tezi sekiz bölüm olarak hazırlanmıştır. Tezin birinci bölümünde, genel bir bakış açısı ile tez çalışmasına yönelik temel bilgiler verilmiştir.

Bölüm 2'de, düşme ve düşme tespitinin kapsamlı açıklaması sunulmuştur. Literatürde düşme tespitine yönelik ortaya konmuş çalışmalar detaylı olarak incelenmiştir. Düşme Tespit Sistemi (DTS) konusu kullanılan sensör türlerine göre gruplandırılarak açıklanmıştır. Literatürde kullanılan sensör türlerine göre, yöntemler arasında ayrıntılı bir karşılaştırma yapılmıştır.

Bölüm 3'te Kinect® derinlik videolarından öznitelik çıkarımını sağlayan Eğrilik Ölçek Uzayı (EÖU), Silüet Yönelim Hacim (SYH) algoritmaları ve bu özniteliklerin kodlanmasını sağlayan Fisher Vektör (FV), Kelime Çantası (KÇ) ile birlikte bu öznitelikleri sınıflandırmak için kullanılan DVM, Naïve Bayes ve k-EYK sınıflandırıcıları hakkında teorik bilgiler verilmiştir.

Bölüm 4'te yaşlı yaşam alanlarından deneysel çalışmalar için ihtiyaç duyulan silüet ve iskelet verilerinin alınmasını sağlayan Kinect® kameranın yapısı ve özellikleri verilmiştir. Düşme tespit çalışmalarında yaygın olarak kullanılan Kinect® derinlik kamerası ile oluşturulan veri setlerine ait temel bilgiler verilmiştir. Ayrıca bu tez çalışması için farklı yaş gruplarındaki 21 denek ile oluşturulan FUKinect-Fall veri setinin oluşturulması ve veri seti özellikleri detaylandırılmıştır.

Bölüm 5'te, derinlik videolarından günlük eylemlerin, düşmelerden ayırt edilmesi için şekil tabanlı düşme tespit yöntemi önerilmiştir. Yöntemin başarımlı değerlendirilmesi için SDUFall veri setine ait silüet verileri kullanılmıştır. Bu çalışmadan elde edilen sonuçlar ile yapılan aşağıdaki çalışmalar kabul edilerek yayımlanmıştır [21, 22].

- Aslan, M., Sengur, A., Xiao, Y., Wang, H., Ince, M. C., & Ma, X. (2015). Shape feature encoding via fisher vector for efficient fall detection in depth-videos. Applied Soft Computing, 37, 1023-1028.

- Aslan, M., Alcin, O. F., Sengur, A., & Ince, M. C. (2015, May). Fall detection with depth-videos. In Signal Processing and Communications Applications Conference (SIU), 2015 23th (pp. 443-446). IEEE.

Bölüm 6’da, düşme tespiti için derinlik videolarındaki görüntülerin SYH tanımlayıcılarına dayalı eylem sınıflandırma ve düşme tespit yöntemi önerilmiştir. Önerilen yöntemin başarımı için yaygın olarak kullanılan SDUFall veri seti kullanılmıştır. Bu çalışmadan elde edilen sonuçlar derlenerek aşağıdaki makale yayımlanmıştır [23].

- Akagunduz, E., Aslan, M., Sengur, A., Wang, H., & Ince, M. (2016, May) Silhouette Orientation Volumes for Efficient Fall Detection in Depth Videos. IEEE Journal of Biomedical and Health Informatics, DOI: 10.1109/JBHI.2016.2570300

Bölüm 7’de FUKinect-Fall veri setindeki, üç boyutlu (3B) iskelet verilerinin, önerilen yöntemle iki boyuta (2B) indirgenmesine dayalı öznetelik çıkarımı ile yeni bir düşme tespit yöntemi önerilmiştir. Bu çalışmalardan elde edilen sonuçlar derlenerek iki ayrı çalışma hazırlanmış olup, bir çalışmanın değerlendirme süreci devam etmektedir. Yayımlanan çalışmanın [24] detayları şu şekildedir;

- Akbulut, Y., Aslan, M., Sengur, A., & Ince, M. (2016, March) Fall Detection with Kinect-Based Skeleton Data , International Conference on Natural Science and Engineering (ICNASE’16), (pp. 131-138)

Sekizinci ve son bölümde, önerilen yöntemlerle yapılan çalışmaların sonuçları irdelenmiş ve özgün katkıları vurgulanmıştır. Ayrıca ileriye yönelik çalışmalar tartışılmıştır.

2. LİTERATÜR İNCELEMESİ

Bu bölümde düşme tespitine yönelik yapılan detaylı literatür taraması sonucu elde edilen bilgilere yer verilecektir. DTS, kullanılan sensör türlerine göre gruplandırılarak sunulacaktır. Ayrıca DTS'lere yönelik ortaya konmuş çalışmaların sonuçları değerlendirilecektir.


2.1. Düşme Tespit Sistemi ve Amacı

Düşme; bir kişinin kendi iradesi dışında durduğu, bulunduğu, tutunduğu yerden dengesini yitirerek yukarıdan aşağıya inmesi ile zemin veya herhangi bir yere çarparak zeminde uzanması ya da başka bir konumda beklemesi ile sonuçlanan bir olay olarak tanımlanmaktadır [15]. Düşme, insanların her yaş döneminde karşılaşılabileceği önemli bir kaza olmakla birlikte daha çok çocuk ve yaşlılar bu kazalara maruz kalmaktadır. Fakat düşme, sonuçları bakımından yaşlıları daha çok etkilemektedir. Çünkü insan organizması zamanın ilerlemesi ile ortaya çıkan, geriye dönüşü olmayan yapısal ve işlevsel değişikliklere maruz kalmaktadır [25]. Bunun sonucu olarak biyolojik ve fiziksel kapasitelerinin azalması sebebi ile yaşlılarda düşme daha ciddi risklere ve halk sağlığı sorunlarına yol açmaktadır. Bu riskleri ve sağlık sorunlarını azaltmak için düşmeye duyarlı akıllı sistemler geliştirilmiş ve bu sistemler, genel olarak DTS olarak adlandırılmışlardır [26].

Bir DTS'nin temel amacı; düşme olayı vuku bulduğunda uyarıcı yardımcı cihazlar yardımıyla olaya en kısa sürede müdahale edilmesini sağlamaktır. Gerçek yaşamda, bir düşmenin olumsuz sonuçlarını önemli ölçüde azaltma potansiyeline sahip DTS'nin genel yapısı Şekil 2.1'de görülmektedir.

Dünyada yaşlı nüfusun hızlı artışı, sağlık ve güvenlik sektörlerinde düşme tespitine yönelik sistemlere olan ihtiyacı daha da arttırmıştır. Çünkü düşme olayına zamanında müdahale ve kurtarmanın tıbbi açıdan çok büyük bir öneme sahip olduğu kanıtlanmıştır [27]. Ayrıca düşmeden sonra kişide düşme korkusu gelişebilmekte, bu korku da ilerleyen zamanlarda düşme riskini daha da artırmaktadır [28]. Düşme korkusunun fiziksel aktivitelerden kaçınma, depresyon, sosyal ilişkileri azaltması ve yaşam kalitesini düşürme gibi olumsuz sonuçları olduğu görülmüştür [29]. Brownsel ve diğerleri, düşme korkusunun otomatik DTS'ler üzerindeki etkisini araştırmışlardır [30]. Yaşamının geçmiş altı ayı içinde

düşmeye maruz kalan yaşlılar ile bir çalışma yürütülmüş ve çalışmanın sonunda, yaşlıların kendilerine uygun olan düşme tespit sistemlerini kullandıklarında bu sistemlerinin onların güvenliğini geliştirdiği fark edilmiş ve onların kendilerini daha güvenli ve özgür hissettikleri tespit edilmiştir [31]. Araştırmanın önemli sonuçlarından biri de düşme sistemlerinin yaşlılarda doğruluk ve güvenilirlik algısı oluşturmaları ile düşme korkusundan büyük oranda kurtulmalarını saptamasıdır.




Şekil 2.1. Düşme tespit sistemin genel yapısı

Ayrıca DTS'ler, düşmeden sonra yaşlının zeminde uzanma süresini de kısaltmaktadır. Bu süre düşme şiddetinin belirlenmesinde önemli bir faktördür. Geçmiş yıllarda yapılan araştırma sonuçlarında düşmeye maruz kalanların büyük bir çoğunluğunun

yardım almadan kalkmalarının mümkün olmadığı tespit edilmiştir. Zeminden kalkamama durumunun uzun sürmesi hipotermi, dehidratasyon ve bronkopnömoni gibi önemli sağlık sorunlarına yol açabilmektedir [31, 32]. Bu durum eğer kişi yalnız yaşıyorsa ve düşmeden sonra bilinç kaybı oluşmuşsa kişi için kritik sonuçlar doğurabilmektedir. Lord ve ekibi, uzun süreli uzanmaları farklı çalışmalarda gözden geçirmişlerdir. Uzun süreli uzanmalar halsizlik, hastalık ve sosyal izolasyon emareleri, yaşlılar arasında yüksek ölüm oranları ile ilişkili olduğunu tespit etmişlerdir [27]. Düşme kaynaklı olarak hastaneye kabul edilen hastaların %20'sinden fazlası bir saat veya daha fazla sürede yerde kaldıkları ve düşme anında doğrudan yaralanmaya maruz kalınmasa da, altı ay içinde hastalanma oranlarının oldukça yüksek olduğu belirtilmektedir [31, 32].


2.2. Düşme Tespit Yöntemleri

DTS'lere yönelik yapılan ilk çalışmalarda, düşme tanımına veya düşme şekline göre bir ayırım yapılmıştır. Bu alanda ortaya konan ilk kapsamlı çalışma 2008 yılında Yu, tarafından gerçekleştirilmiştir [33]. Bu çalışma; düşmeyi başlangıç konumlarına dayanarak üçe ayırmıştır. Bunlar, yürürken veya ayakta beklerken düşmek, otururken düşmek ve uyurken düşmek olarak tanımlamıştır. Bu üç düşme türü önemli özellikler bakımından birbirinden ayrılrsa da bazı yaşamsal aktivitelerin de düşme olarak tanımlanmasını sağlayacak ortak özelliklere de sahiptir. Örneğin çömelme hem hızlı bir düşmeyi gösterirken hem de günlük yapılan normal bir eylemdir. Araştırmacılar tarafından yapılan farklı düşme tanımları aynı zamanda düşmenin de farklı şekillerde gruplandırılmasına neden olmuştur. Noury ve diğerleri, sadece çarpma şoklarının tespitine odaklanma veya düşme sonrası durumlara göre farklı bir gruplandırma çalışması yapmışlardır [34]. Buna karşılık, Mubashir ve ekibi, düşme tespitinde kullanılan sensör türünü referans alarak giyilebilir sensör tabanlı yöntemler, ortam duyarlı sensör tabanlı yöntemler ve görüntü tabanlı yöntemler olmak üzere Şekil 2.2'de gösterildiği gibi bir gruplandırma yapmışlardır [34]. Şekil 2.2'de ayrıca her bir yöntemde kullanılan sensör türlerine göre alt sınıflandırmalar yapılmıştır. Araştırmacıların büyük çoğunluğu DTS'lerde Mubashir ve diğerlerinin [35]'deki çalışmasını referans almaktadırlar. İnternet teknolojisinin gelişmesiyle mobil ve bulut hesaplamayı içeren i-uzay tabanlı sistem de dördüncü yaklaşım olarak ortaya konmuştur [36]. Fakat bu alanda henüz kapsamlı bir çalışma tespit edilmemiştir.



Şekil 2.2. Düşme tespit yöntemleri

DTS'lerde kullanılan sensör türleri farklılık gösterse de düşme tespitindeki algoritmaları aynı ya da benzerlik göstermekte ve genel çalışma yöntemleri Şekil 2.3'te görüldüğü üzere üç ana bölümden oluşmaktadır. Düşme tespiti için kullanılan sensörlerden alınan ham verilerden faydalanarak özellik çıkarımı yapıldıktan sonra eylemler düşme olarak sınıflandırılır. Düşme tespit edildiğinde aile bireyleri ve acil müdahale merkezine bildirimler iletilir.



Şekil 2.3. DTS'lerin genel çalışma yöntemleri [37]

2.2.1. Giyilebilir Sensör Tabanlı Yöntemler

Giyilebilir sensör tabanlı yöntemlerde; kişinin vücut konumunu ve hareketini tespit etmek için ivmeölçer, jiroskop, manyetometreler, eğim, hareket ve barometrik basınç gibi sensörler kullanılır. Bu sensörler kişinin giydiği elbiseler içerisine veya kol, boyun, bel ve kafa gibi vücudun değişik bölgelerine yerleştirilir. Clifford ve diğerleri, giyilebilir sensör tabanlı düşme yöntemlerinin temel yapısının ivmeölçer sensör dizisi, işlemci ve kablosuz vericiden oluştuğunu belirtmişlerdir [38].

Düşme tespitine yönelik ortaya konan çalışmaların başlangıç aşamasında giyilebilir sensör tabanlı yöntemler daha yaygın olarak kullanılmıştır. Bu alandaki ilk çalışma 1970'li yılların başlarında geliştirilmiştir. Tasarlanan sistem kullanıcı tarafından uzaktan vericinin düşmesine basıldığında bir uyarı mesajı gönderebilecek şekilde oluşturulmuştur [38]. Loard ve Colvin, yaşlı düşmelerini önlemek amacıyla yaşlılarda düşme nedenleri ve etkilerini inceledikten sonra düşme tespiti için bir ivmeölçer kullanılmasını önermiştir [39]. İlk prototip sistem William ve arkadaşları tarafından 1998 yılında geliştirilmiştir [40]. William düşme tespiti için piezo elektrik şok sensörü kullanmıştır. Ayrıca cıva eğim anahtarı ile düşme sonrası kişinin yönelimi yönünü tespit etmişlerdir. 2002 yılında Prado ve diğerleri, bel yüksekliğinde kullanıcının arkasına bir yama olarak giyilen iki adet çift eksenli ivmeölçere dayalı düşme tespit sisteminin prototipini geliştirmişlerdir [41]. Noury titreşim sensörü, pozisyon yönelim anahtarı ve piezo elektrik ivmeölçerden oluşan akıllı düşme sistemi geliştirmiştir [42]. Sistem basit bir algoritma ile geliştirilmiş olmasına rağmen sonuçlar algoritmanın oldukça hassas olduğunu göstermiştir. Degen ve çalışma ekibi, yaşlılar için bileğe takılan düşme dedektörünü geliştirmişlerdir [43]. Bu sensörün giyilmesi kolay olmasına rağmen düşük oranda bir başarımlı sağlayabilmiştir. Lin ve diğerleri bir akıllı ceket içerisine gömülmüş 9 küçük cıva anahtarı ve optik sensörlere dayanan bir düşme tespiti önermişlerdir [44]. Optik sensörlerin düşme tespiti için kullanıldığı ve belin sol tarafına yerleştirilen küçük cıva anahtarlar ile düşme özelliklerini (öne veya arkaya) ve kullanıcı eylemlerini (uzanma, oturma, ayakta bekleme veya öne doğru eğilme gibi) tanımlayabilen sistem geliştirmişlerdir. Binachi ve diğerleri, kemere yerleştirilen üç eksenli bir ivmeölçer ve barometrik basınç sensör temelli bir düşme tespit sistemi geliştirmişlerdir [45]. Bel ile zemin arasındaki atmosferik basınç değerinin farklı olduğu varsayımına dayanarak yapılan deneysel çalışma sonuçlarından sensörlerin düşme tespiti için faydalı bilgiler sağladığını tespit etmişlerdir. Dia ve diğerleri mobil telefon tabanlı düşme tespitinin kullanımını

tanıtmışlardır [46, 47]. 2011 yılında Gjoreski ve ekibi, göğüs, bel, kalça ve ayak bileğine üç eksenli ivmeölçerler yerleştirerek düşme tespiti yapmışlardır [48]. Göğüs ve bele sensör yerleştirilmesinin düşme tespiti için uygun olmasına rağmen ancak dört sensörün birlikte kullanımı ile en iyi performansın elde edilebildiğini belirtmişlerdir. Son zamanlarda, akıllı telefonlara gömülü üç eksenli ivmeölçer ile yapılan düşme tespiti giderek popüler hale gelmiştir. Zhao ve diğerleri bel, göğüs ve kalça üzerine konumlandırılmış bir akıllı telefon ile düşme tespit doğruluklarını karşılaştırmış ve göğüsün düşme tespiti için en iyi konum olduğunu belirtmişlerdir [49]. Düşme tespiti için akıllı telefon kullanmanın avantajı düşenin konumun izlenebilmesi ve uyarı mesajı gönderiyor olabilmesidir.

Düşme tespit sistemlerinde, kullanılan sensör veya sensörlerin seçimi kadar düşmelerin tespit edilmesini sağlayacak algoritmalar da büyük öneme sahiptirler. Giyilebilir sensör tabanlı sistemlerde algoritmaların büyük çoğunluğunda belirli bir eşik değeri referans alınmaktadır. Ayrıca bu algoritmalar aynı zamanda düşmeden sonra kişinin duruşu hakkında da bilgiler verebilmektedir. Bourke ve ekibinin, laboratuvarında yetişkin denekler ile yapılan çalışmada düşme ve düşmenin olmadığı eylemlerde üç eksenli ivmeölçerden gelen işaretleri kaydetmiştir [50]. Düşme tespit algoritmasını ilk aşama, darbe aşaması ve kurtarma aşaması olarak analiz etmişlerdir. Bianchi ve diğerleri, 20 genç denek ile yaptıkları çalışmada, günlük eylemleri düşmelerden ayırt etmede sezgisel eğitilmiş karar ağacı sınıflandırıcısının doğruluğu daha da geliştirdiğini tespit etmişlerdir [45]. Kangas ve diğerleri, üç orta yaşlı denek ile baş, bel ve bileklerine bağlanan üç eksenli ivmeölçer ile günlük eylemleri ve düşmeyi tespit amacıyla bir çalışma yapmışlardır [51]. Bel ve başa takılan ivmeölçer ile yapılan çalışmalarda, düşmenin daha etkin olarak tespit edilebildiğini belirtmişlerdir.

Giyilebilir sensör tabanlı yöntemlerin avantajlarının yanı sıra dezavantajları da vardır. En büyük avantajı giyilebilir sensörlerin maliyet verimliliğidir. Sistem tasarımı, kurulumu ve montajı çok karmaşık değildir. Sistemin çalıştırılması diğer yöntemlere göre daha kolaydır. Fakat sensör bağlantılarının kolayca ayrılması kullanan kişi ile bağlantının kesilmesine yol açmaktadır. Ayrıca uzun bir süre için onu giyen kişinin günlük aktivitelerinde rahatsızlıklara neden olması ve şarj gereksiniminden dolayı hatalı bildirimlerde bulunabilmesi yöntemin dezavantajlarıdır. Bu tür dezavantajlarından dolayı yaşlılar tarafından daha az tercih edilmektedirler [52-72].

2.2.2. Ortam Duyarlı Sensör Tabanlı Yöntemler

Ortam duyarlı sensör tabanlı düşme tespit yöntemlerinde, duvara veya tavana monte edilmiş mikrofonlar ve zemine veya mobilyalara gömülü basınç, titreşim ve kızılötesi sensörler kullanılmaktadır. Bu tür yöntemlerin en büyük avantajı kişinin herhangi bir sensör yerleştirilmiş özel bir elbise giymesi veya cihazı takmak, üzerinde bulundurmak zorunda kalmamasıdır. Alwan ve diğerleri, düşme tespiti yapabilmek için zemine yerleştirilmiş titreşim sensörlerini kullanmışlardır [52]. Zeminde çeşitli nesnelerin ve mankenlerin düşürülmesi ile veriler elde etmişlerdir. Zemindeki titreşim sensörleri ile nesne ve manken düşmesini ayırt etmede önemli başarımlar sağlamışlardır. Li ve diğerleri otomatik düşme tespiti için akustik düşme tespit sistemi geliştirmişlerdir [53]. Bu amaçla, yaşlının yaşam alanındaki düşme ve düşme olmayan seslerin etkili bir biçimde alınabilmesi için dairesel bir mikrofon dizisi oluşturmuşlardır. 3 denek ile gerçekleştirilen çalışma sonucunda düşme ve düşme olmayan eylemleri hatasız olarak ayırt etmişlerdir. Toreyin ve diğerleri ses, pasif kızılötesi hareket ve titreşim sensörleri ile donatılmış akıllı bir ortamdaki ses çokluğu ile düşme tespiti gerçekleştirmiştir [54]. Zhuang ve diğerleri bir uzak alan mikrofondaki ses sinyallerini kullandıkları bir yöntem önermişlerdir [55].

Ortam duyarlı sensörler ile yapılan düşme tespitlerinde çoğunlukla basınç ve akustik sensörler kullanılmaktadır. Basınç sensörleri basınç değişimine bağlı olarak düşme tespiti yapmaları nedeni ile kişi düşmesi dışında herhangi bir nesnenin düşmesi de basınç değişimine neden olabileceğinden hatalı bildirimlere sebep olabilmektedir. Aynı şekilde sese dayalı yapılan düşme tespitlerinde kullanılan mikrofonlar da kişi düşmesi dışında ortamdaki diğer sesleri algılamakta ve bu durum hatalı bildirimlere neden olabilmektedir. Ortam duyarlı sensörlerin düşme tespitinde tek başına kullanımı istenilen verimi sağlayamamaktadır. Ancak pasif kızılötesi, basınç ve mikrofon gibi ortam duyarlı sensörlerin birlikte kullanımı ile istenilen başarımlar sağlanabilmektedir. Bu durumda düşme tespit sisteminin maliyetini arttırması ve yaşlıların bulunduğu bir ortamda bu kadar çok sensör kullanımı, sağlık açısından da yan etkilere neden olabilmektedir. Sayılan dezavantajların bu sistemlerin tercih edilebilirliğini düşürmektedir [15, 56].

2.2.3. Görüntü Tabanlı Yöntemler

Akıllı görme, kamera, video ve gerçek zamanlı hareketlerin kullanıldığı görüntü işleme tekniklerinde son 20 yılda birçok gelişmeler olmuştur. Bu gelişmeler önemli bir halk sağlığı problemi olan yaşlı düşmeleri tespiti sorunun çözümü için yeni çalışma imkanları sunmaktadır. Görüntü tabanlı düşme tespit yöntemleri diğer düşme tespit yöntemleri ile karşılaştırıldığında; yaşlıların ivmeölçer gibi bazı özel sensörler içeren herhangi bir cihaz giymek zorunda kalmamaları, basınç sensörleri ve mikrofonlar gibi ev ortamındaki gürültülerden kolayca etkilenmeme gibi bazı önemli avantajları sağlamaktadırlar. Görüntü tabanlı düşme tespit yöntemleri, kendi içerisinde kullanılan kamera türlerine göre iki ayrı grupta incelenebilirler. İlk grupta geleneksel Kırmızı Yeşil Mavi (KYM) renkli kameraların kullanımı ile düşme tespiti yapılmıştır. Diğer çalışmalar ise Kırmızı Yeşil Mavi -Derinlik (KYM-D) kameralarının kullanımını içermektedir.

2.2.3.1. KYM Renkli Kameralar ile Yapılan Düşme Tespit Çalışmaları

Görüntü tabanlı düşme tespit sistemlerinde, 2011 yılına kadar yaygın olarak geleneksel KYM kameralar kullanılmıştır. Geleneksel KYM kamera kullanılarak yapılan düşme tespit çalışmalarında kameranın konumu, kullanılan kamera sayısı gibi özellikler referans alınarak birçok çalışma yapılmıştır [15, 56].

Tek renkli kamera kullanılarak yapılan çalışmalarda, genellikle 2B görüntüler kullanılmıştır. Bu alanda yapılan ilk çalışmalardan birini Anderson ve çalışma ekibi, tek bir KYM kameradan alınan görüntülerin silüet boyut analizlerinin ortaya konulması ile başlamıştır [57]. Bu çalışmalarında kişilerin ağırlık boy oranları özelliklerini kullanarak düşme tespiti yapmışlardır. Huang ve diğerleri, lineer bir sınıflandırıcı ile düşme ve düşme olmayan eylemleri ayırt etmek için silüet boyut değişimlerini ve vücut görünüm oranları birleşimlerinden yararlanmışlardır [58]. Kişinin kilo, boy, sağlık geçmişi gibi kişisel bilgileri ve aynı zamanda ağırlık değişimlerini lineer sınıflandırıcıya uygulamışlardır. Bu özellikler kullanılarak sınıflandırma ağırlıkları değiştirilerek daha etkili bir düşme tespiti yapmayı amaçlamışlardır. Tek KYM kamera ile yapılan bu iki çalışmada, yaşlının yaşam alanındaki eşya ve mobilyaların kamera önünü kapaması dikkate alınmamıştır. Bu nedenle birçok bilimsel çalışmada, düşme tespit sistemlerin performansını arttırmak için yaşam alanı aktif ve aktif olmayan bölgelere ayrılmıştır. Lee ve diğerleri, çalışmalarında kamerayı üstten

görüntü alabilecek şekilde tavana yerleştirmişlerdir [59]. Yaşlı yaşama alanından alınan bu görüntülerdeki mobilyalı (sandalye, kanepeler, yataklar gibi) alanları aktif olmayan bölgeler olarak tanımlamışlardır. Böylece DTS aktif olmayan bölgedeki bir uzanma eylemini normal bir eylem olarak tanımlarken, aynı eylem aktif olan bölgede meydana geldiğinde bu durumu düşme olarak tespit etmektedir. Ayrıca aktif bölgedeki uzanma eylemini, düşmelerden ayırt edebilmek için ağırlık merkezinin konumunu, hızını verilen eşik değeri ile karşılaştırılarak gerçek düşmeleri bu şekilde tespit etmişlerdir. Bir diğer benzer çalışmada Charif ve McKenna, aktif olmayan bölge olarak tanımlanan mobilyalı alanlarda kişilerin çoğu zaman televizyon seyretmek, gazete okumak, çay içmek gibi dinlenme eylemlerini yapıyor olması bu alanların aktif olarak kullanıldığını belirtmişlerdir [60]. Bu nedenle aktif olmayan bölgeler olarak bilinen alanlarda herhangi bir hareketlilik olup olmadığını kontrol edip izlemişlerdir. Aktif olmayan bölgeler dışındaki hareketsizlikleri ise daha çok düşme olaylarına işaret ettiğini belirtmişlerdir. Fakat bu iki yöntemin de çok sayıda kısıtlama içeriyor olması 2B silüetlerde yapılan hız tahminleri, dağınık arka planlar ve insanların çeşitli günlük eylemlerinden çok etkilendiğini ortaya koymuştur. Ayrıca çevresel değişimlere uyum sağlamada da yetersiz kalması nedeniyle, üstten çekim yapan kameraların düşmeleri tespit etme problemi için uygun olmadığı görülmüştür [15, 56, 60].

Daha etkili düşme tespit çalışmaları için 2B yerine 3B bilgilerinden yararlanmak için etkili bir çözüm de, iyi kalibreli edilmiş tek kamera kullanmaktır. Rougier ve diğerleri, parçacık filtresini temel alan bir yöntem kullanmışlardır [61]. Bu yöntemde, kafa 3B olarak takip edilerek düşme kararının verilebilmesi için kafanın hızını elde etmişlerdir. Buldukları bu çözümün çok hızlı bir şekilde oturma gibi şaşırtıcı eylemlere bile duyarlı olduğu görülmüştür. Cucchiara ve diğerleri ayakta durma, oturma, yatma ve çömelme gibi pozları sınıflandırmak için eğitilmiş olasılıklı kestirim haritalamayı geliştirmişlerdir [62]. Bu ekip, kameranın önünün kapanması durumlarında güvenilir tanımlama yapabilmek için, bir takip algoritması kullanılmasını ve bir durum değişim grafi yardımıyla sonuca gidilmesini önermektedirler. Daha sonra yayınladıkları çalışmalarında ise önceki çalışmalarını geliştirerek, yaşam alanında birden fazla oda olması durumlarında çok sayıda ve görüş alanları birbiriyle kısmen kesişen kameralar kullanmayı önermişlerdir [63]. Aynı kişinin değişik odalarda dolaştığı durumlarda bir kameradan diğerine geçiş yapılabilmesi için, kişi şeklinin homografına bakılarak görüntüler arasında geçiş yapılması sağlanmıştır. Geçiş işlemi aynı zamanda mobilya nedeniyle görüntünün kapanması probleminin azaltılmasında önemli katkılar sağlamıştır. Daha sağlam ve etkili tanımlama sonuçları elde etmek için Saklı

Markov Model (SMM) eğitilmiştir. Çok sayıda kamera kullanılıyor olsa da son karar, o anda kişiyi izlemekte olan tek bir kamera tarafından bağımsız olarak verilerek daha etkin bir düşme tespiti yapmaya çalışmışlardır.

Özet olarak, tek bir kameradan elde edilen 2B uzamsal parametrelerin, düşmeyi diğer eylemlerden ayırt etmede istenilen performansı sağlamadığı görülmektedir. Kameraların optik eksenine paralel yönde olan düşmeler de tek yönden bakışlı yaklaşımlar da zorluklara neden olmaktadır. Ayrıca kameraların görüş noktalarıyla, önlerinin kapanmasıyla, aktif ve aktif olmayan bölgeleriyle ilgili çok sayıda varsayım yapılması ve bunların gerektirdiği yüksek işlem gücü, tek noktadan bakışlı yaklaşımları yeterli kılmamaktadır. Bu sebeple araştırmacılar tek renkli kamera yerine daha fazla sayıda renkli kamera kullanarak daha iyi hassasiyete sahip düşme tespit sistemleri geliştirmeye çalışmışlardır [15, 56].

Thome ve diğerleri, elips modellerindeki dikey çizgiyle asal eksen arasındaki 3B açıyı türetmek için metrik görüntü düzeltme kullanmışlardır [64]. İnsan duruşlarını tanımlarken bulanık durumlar çok sayıda kameranın birbirinden bağımsız kararları kaynaştırılarak SMM katmanını olaylardan çıkarım yapabilecek şekilde tasarlamışlardır. Hazelhoff ve diğerleri, iki kalibre edilmemiş ve birbirine dik duran kamera kurmuşlardır [65]. Temel bileşen analizi kullanılarak vücudun ana ekseninin yönünü ve kartezyen koordinat sistemindeki yönelim oranları ile düşme olaylarını çok çerçeveli bir Gauss sınıflandırıcı ile tespit etmişlerdir. Bunun için deri renk bilgisi referansı ile kafa takibi kontrolü gerçekleştirilmiştir.

Anderson ve diğerleri, kişi vokseli (3B görüntü işlemede en küçük görüntü ögesi) oluşturulmasına referans alan bir düşme tespit sistemi geliştirmişlerdir [66]. Bu düşme tespit sistemi için durum çıkarım ve insan durumlarını sınıflandırmak için bulanık mantık hiyerarşisi önermişlerdir. Bulanık mantığın dilbilimsel yönü bu sistemi rahat kullanılabilir hale getirmektedir. Kullanıcı, kavramasına ve fiziksel yeteneklerine göre özelleştirmeler yapabilmektedir. Zambanini ve diğerleri, [65]'teki çalışmayı referans alarak çalışmalarında düşük işlem maliyetini öne çıkarmıştır [67]. Burada fiziksel görünüş oranları, yönlendirme, eksen oranları ve hareket hızı gibi bilgileri düşük maliyetli olarak voksel uzayından elde etmişlerdir. Anderson ve diğerleri, başka bir çalışmalarında [65]'teki çalışma ile benzer bulanık mantık tabanlı duruş tahmini kullanmalarına rağmen, düşme güvenlik değerlerinin hesaplanmasına dayalı daha az karmaşık bir mantık mekanizması kullanarak gerçek zamanlı performans sağlamaya çalışmışlardır [66]. Auvinet ve diğerleri ise kamera ağından 3B insan vücut modelini yeniden inşa etme yöntemini değerlendirmişler ve dikey hacim dağılım oranı

fikrini önermişlerdir [68, 69]. Çünkü kişinin uzanma ve ayakta bekleme anındaki hacimlerinin dikey olarak önemli farklılıklar gösterdiğini belirtmişlerdir. Önerilen yöntem ile 3B insan modelinin yeniden oluşturulmasında çoklu kameralardan yararlanılması ve ayrıca yaşam alanlarındaki eşya ve mobilyaların neden olduğu tıkanıklığın da kontrol edilebilir olmasını sağlamışlardır.

Yukarıdaki çalışmalarda da görüldüğü gibi düşme tespitinde çoklu kamera kullanımı bazı avantajlar sağlamıştır. En önemli avantajı 3B uzamsal parametrelerin çıkarılması imkanı, yani bir voksel kişi ve 3B silüetler oluşturulmasıdır. Bu yaklaşımlar duruşları ve durumları sınıflandırmada çok daha başarılıdır. Ayrıca çoklu görüş açısından elde edilen parametreler tek görüşten elde edilenlere göre daha güvenlidir. Çünkü kapalı alanlarda kameranın önünün kapanması durumu çok sık gerçekleşmektedir. İnsanlar bir kameranın bakış açısından görülemiyor olabilir fakat çok büyük ihtimalle diğer kameralardan görülebiliyor olacaklardır. Yani çok görüş yönlü yaklaşımlar kameranın önünün kapanma problemiyle, tek görüş yönlü yaklaşımlara kıyasla çok daha iyi başa çıkabilmektedir. Diğer taraftan çok bakış yönlü yaklaşımlarda da bazı kısıtlamalar vardır. Öncelikle yeni kameraların eklenmesi yöntemleri daha karmaşık hale getirir ve daha fazla hesaplama kaynağı gerektirmektedir [15, 56]. Fakat Grafik İşleme Ünitesi (GIÜ) gibi hesaplama birimlerinin gelişmesiyle birlikte bu sorun ortadan kalkabilir. İkinci kısıtlama, yeni kameraların eklenmesinin gözlemlenen alanı daraltmasıdır. Diğer türlü ev ortamında çok geniş çekimler yapılması için lens kullanmak gerekebilir, bu da son derece bozulmuş görüntülere yol açar. Üçüncü olarak da çok görüntülü yaklaşımlarda çalışma esnasında senkronize olmaya, kalibrasyona ve kaydedilmeye ihtiyaç duyulmaktadır. Fakat kalibrasyonun yapılması ve kamera ağlarının çalışma esnasında kaydedilmesi zor bir işlemdir. Çok görüşlü yaklaşımların performansı, çevre görüntüsünün değişmesi ve bakış açısının değişken olması durumunda, tekrar kalibrasyon ve kayıt yapılmaz ise bir anda hiç beklenmedik şekilde kötüleşebilmektedir [56, 70].

2.2.3.2. KYM-D Kameralar ile Yapılan Düşme Tespit Çalışmaları

Geleneksel renkli kameralar ile yapılan düşme tespit sistemleri yaşlıların mahremiyet endişesinden dolayı daha az tercih edilmektedir. Bilgisayarlı görüntüleme teknolojilerindeki son gelişmeler ile birlikte geleneksel kameralar yerine kullanılabilecek derinlik tespitini de algılayabilen kameralar üretilmiştir. Bu kameralar, geleneksel kameralar göre ışık

yoğunluğundaki değişimlere daha az duyarlı, kompakt yapıya sahip ve düşük maliyetli olması gibi avantajlara sahiptir [71]. Ayrıca bu kameralar ile yapılan düşme tespit sistemlerinde insanın gerçek görüntüsü yerine silüetinin kullanılıyor olması, geleneksel KYM kameralardaki yaşlıların mahremiyet endişelerini de giderebilmektedir. Düşme tespitini algılayan diğer yöntemler ile karşılaştırıldığında derinlik kamerası, kişi hakkında daha zengin anlamsal bilgilerin yanı sıra onu çevreleyen ortam hakkında da bilgi sağlayabilmektedir [71, 72]. Bu nedenle araştırmacılar tarafından düşme tespit çalışmalarında geleneksel renkli kameralar yerine derinlik kameraları yaygın olarak kullanılmaya başlanmış ve bunun için çeşitli algoritmalar geliştirilmiştir [15, 56, 71, 72].

Bian ve diğerleri, derinlik kamerası kullanarak düşme tespiti için insan eklem bilgilerini düşünmüşlerdir [73]. İskelet eklemlerinin zemine olan uzaklığı ve eklem hızları referans özellikler olarak kabul edilmektedir. Akagündüz ve diğerleri, derinlik videolarını kullanarak silüet resim yönelimlerine dayalı şekil dizi tanımlayıcı yöntem önermişlerdir [23]. Sabit uzunluktaki silüet çerçevelerinden bir eylem videosunda ait özellik vektörü oluşturulduktan sonra kelime çantası ile kod çizelgeleri oluşturulmuş ve daha sonra Naïve Bayes sınıflandırıcı ile eylemler sınıflandırılmıştır. Ma ve diğerleri, Kinect® derinlik kamerasında video silüetlerinden, EÖÜ özellikleri ve geliştirilmiş Aşırı Öğrenme Makinaları (AÖM) sınıflandırıcı kullanılarak şekil tabanlı düşme tespiti yöntemi önermişlerdir [74]. Diğer bir çalışmada, derinlik kamerası sahte düşme pozlarını tespit için tavana monte edilmiştir [75]. Tespit edilen insan vücut alanı ve önemli şekil uzunlukları gibi özellikler k-EYK sınıflandırıcı ile düşme tespiti ve günlük eylemleri sınıflandırmışlardır. Dubois ve diğerleri, düşme tespiti için bir başka derinlik sensör tabanlı sade fakat geçerli bir yaklaşım önermektedirler [21]. Yöntem temel olarak deneyin kütle merkezini izlemektedir. Bu çalışmada SMM; izlenen vücut şekli, kütle merkezinin hızı ve kütle merkezi pozisyonun gözlemleri ile düşme tespiti yapmışlardır. Tinetti ve diğerleri, iskelet eklem özellikleri kullanılan başka iskelet tabanlı DTS önerilmişlerdir [32]. Çalışmada özellikler olarak yapı-hareket-tabanlı iskelet istatistikleri serisini incelemişlerdir. Görüntü ve derinlik tabanlı özellikleri daha da geliştirilmesi için bir araya getirmişlerdir.

Genelde görüntü tabanlı yöntemlerin yapıları benzerdir. Bunların çoğunda nesnenin tespiti için arka planın çıkarımı [60-65] veya gözlem sensörlerinden sağlan bilgiler [53] ile başlandığı görülmektedir. Bazı yöntemler de nesnelerin konumunu filtrelemek için izleme algoritmalarını dikkate almıştır [71-76]. Daha sonra, düşme olaylarını tanımlamak için yeterli ayırt ediciliğe sahip olması gereken öznitelikler, tespit edilen nesnelerden çıkarılarak

düşme tespiti yapılır. Bu özellikler Gauss Karışım Modeli (GKM) [73], Kural tabanlı teknikler [65], çoklu çerçeve Gauss sınıflandırıcılar [64], eşikleme teknikleri [46, 63, 67], SMM [68], bulanık mantık [69] gibi yaygın teknikler kullanılarak düşme veya düşme olmayan olayları sınıflandırmak için kullanılırlar.



3. MATERYAL VE YÖNTEM

Bu bölümde tez çalışmasında kullanılan öznitelik çıkarımı, özniteliklerin kodlanması ve sınıflandırılması gibi kuramsal alt yapıyı oluşturan yöntemler hakkında bilgilere yer verilecektir.

3.1. Öznitelik Çıkarım Yöntemleri

Silüetler başka bir deyişle düzlemsel şekillerin kenarları, nesne özellikleri hakkında önemli bilgiler sağlamaktadır. Özellikle detay ve doku düzeyinin düşük olduğu görüntüleme ortamlarında, silüetler nesne tanıma amaçlı tek bilgi kaynağı olabilmektedirler [77]. Otomatik veya yarı otomatik bölütleme yöntemleri kullanılarak bir nesnenin çevre sınırları bölütlenebilir ve çıkarılan silüet, nesneleri sınıflandırmak için kullanılabilir. Ayrıca bir nesne veya silüet birçok farklı ölçeklerde yapılar içermektedirler. Böylece gerçek bir gösterim (temsil) yalnızca nesnenin veya silüetin farklı ölçeklerinden elde edilen bilgiler kullanılarak oluşturulabilmektedir. Bu bölümün devamında silüetlerden öznitelik çıkarımını sağlayan EÖU ve SYH yöntemleri incelenmiştir.

3.1.1. Eğrilik Ölçek Uzayı

Bilgisayar görme sistemleri, giriş görüntü verilerinden sahnedeki bazı önemli olabilecek durumları çıkarmakta veya bazı öngörülemeyen sonuçlara ulaşmamızı sağlamaktadır [78-82]. Bunun için görüntüdeki nesnelerin şekil özelliklerini kullanmak ve şekillerin bazı bilgilerinden faydalanmak çok sıkça başvurulmuş bir durumdur. Bu nedenle araştırmacılar şekil analizi alanında birçok çalışma yapmışlardır. Bunlardan biri de Farizan Makhtanian tarafından 1990'lı yıllarda geliştirilmiş etkili ve güçlü şekil analizi yapabilen EÖU yöntemidir. Bu yöntem, düzensiz biçimli 2B şekillerin değişmeyen yerel özelliklerinden çok ölçekli yapıya dönüştürülmesini sağlamaktadır [78-85]. EÖU görüntülerde kullanılan özellikler, çözünürlüğün çoklu ölçeklerdeki şekillerinden elde edilen eğrinin sıfır geçiş noktalarından faydalanmaktadır [83-85]. Eğrideki noktaların örneklenmesi gerektiğinde, eğrinin sağlamlığı için eşit uzaklıklarda seçilirler. Eğrinin tamamının temsil edilebilmesi amacıyla noktalar yeterli çözünürlükte tüm dış hatlar (eğri)

boyunca işaretlenir. Eğer temsil edilen eğrinin bazı bölümleri engellenmiş veya diğer sınırlamalar nedeniyle eksik ise gösterim kısmi olarak kabul edilir.

EÖU gösterimi öteleme ile değişmediğinden sahnedeki şeklin konumu dikkate alınmamakta ve dönmeden de etkilenmemektedir [72-85]. Sadece gerçek görüntünün dairesel yer değişimleri sonucu şeklin yönelimi değişmektedir. Diğer bir ifade ile örneklenmiş şekil kenar noktaları kümesi için başlangıç noktasının değiştirilmesi, aynı şekillerin döndürülmüş versiyonlarına karşılık gelmektedir. Gösterilen şeklin sınırları olası ölçeklere karşılık gelen ölçek değerlerinin sürekliliği ve aynı sayıda eşit aralıklı sınırlar ile tüm şekiller bilinerek EÖU'nun ölçek değişmezliği kolayca tahmin edilebilir [80-85].

EÖU aynı şekil sınırlarına sahip eğrilerin gösterimini sağlamaktadır. Bu bakımından bu şekillerin doğru sınıflandırılması oldukça önemlidir. Çünkü çevirme, döndürme ve herhangi bir ölçek değişimi sonucu tanınmasını etkilememektedir [83]. Aynı gösterime sahip olan, aynı şekil sınırları ile iki eğrinin EÖU gösterimi değişmezdir [80-84]. Son olarak, gösterimlerdeki küçük farklılıklar küçük şekil değişimlerine karşılık gelmekte ve iki eğrinin küçük şekil farklılıkları gösterimlerinde küçük farklılıklara karşılık gelmesi kararlılık özelliğinin olduğunu göstermektedir.

Bir düzlemsel eğri, vektör değerli fonksiyonun sürekli değerleri olan konum vektörünün noktaları kümesidir. Bu parametrik vektör aşağıdaki gibi yazılabilir.

$$r(u) = (x(u), y(u)) \quad (3.1)$$

$r(u)$ eğrinin parametrik fonksiyonunu, x ve y r eğrisinin koordinatlarını göstermektedir. Bir düzlemsel eğri, sonsuz sayıda farklı parametrik gösterime sahiptir [86]. Eğrinin doğal parametrizasyonu olarak adlandırılan s yay uzunluğu parametresi bir parametrik gösterimdir [86-88]. Doğal parametrizasyon denklem 3.2 kullanılarak rastgele parametreler ile hesaplanabilir [12].

$$s(u) = \int_0^u |\dot{r}(v)| dv \quad (3.2)$$

Burada $\dot{r}$, $\dot{r} = dr / dv$ şeklindeki birinci türevi ifade etmektedir. Herhangi bir parametrizasyon için denklem 3.3 aşağıdaki gibi yazılabilir [87];

$$\begin{aligned}
\dot{r}(u) &= (\dot{x}(u), \dot{y}(u)) \\
|\dot{r}(u)| &= (\dot{x}^2 + \dot{y}^2)^{1/2} \\
t(u) &= \frac{\dot{r}}{|\dot{r}|} = \left(\frac{\dot{x}}{(\dot{x}^2 + \dot{y}^2)^{1/2}}, \frac{\dot{y}}{(\dot{x}^2 + \dot{y}^2)^{1/2}} \right) \\
n(u) &= \left(\frac{-\dot{y}}{(\dot{x}^2 + \dot{y}^2)^{1/2}}, \frac{\dot{x}}{(\dot{x}^2 + \dot{y}^2)^{1/2}} \right)
\end{aligned} \tag{3.3}$$

Burada $t(u)$ ve $n(u)$ sırasıyla u 'nun teğet ve normal vektörlerini göstermektedir. Herhangi bir düzlem eğrisi için $t(u)$ ve $n(u)$ vektörleri basitleştirilmiş Serret-Frenet vektör sistemlerine uygun olarak denklem 3.4'teki gibi yazılabilir [86];

$$\begin{aligned}
\dot{t}(s) &= \kappa(s)n(s) \\
\dot{n}(s) &= -\kappa(s)t(s)
\end{aligned} \tag{3.4}$$

Buna göre s olarak tanımlanan eğrinin, $\kappa(s)$ eğriliği Denklem 3.5 ile hesaplanabilir [89];

$$\kappa(s) = \lim_{h \rightarrow 0} \frac{\phi}{h} \tag{3.5}$$

ϕ ; $t(s)$ ve $t(s+h)$ teğetleri arasındaki açıyı belirtmektedir. Denklem 3.5'e göre denklem 3.4 düzenlenirse, denklem 3.6'daki bağıntı yazılabilir [86, 89].

$$\begin{aligned}
\dot{t}(s) &= \frac{dt}{ds} = \frac{dt}{du} \frac{du}{ds} \\
\frac{dt}{du} &= \frac{ds}{du} \kappa(n) = |\dot{r}| \kappa(n)
\end{aligned} \tag{3.6}$$

Böylece $\kappa(u) = \frac{\dot{t} \cdot \dot{n}}{|\dot{r}|}$ bağıntısı yazılabilir. Bu durumda $t(u)$ için denklem 3.7'de görülen bir ifade yazılabilir [85-87].

$$t(u) = \left(\frac{-\dot{y}(\ddot{x}\ddot{y} - \ddot{x}\ddot{y})}{(\dot{x}^2 + \dot{y}^2)^{3/2}}, \frac{\dot{x}(\ddot{x}\ddot{y} - \ddot{x}\ddot{y})}{(\dot{x}^2 + \dot{y}^2)^{3/2}} \right) \quad (3.7)$$

Buna göre $\kappa(u)$ için (3.8)'deki bağıntı yazılabilir [89].

$$\kappa(u) = \frac{\dot{x}(u)\ddot{y}(u) - \dot{y}(u)\ddot{x}(u)}{(\dot{x}(u)^2 + \dot{y}(u)^2)^{3/2}} \quad (3.8)$$

Burada, $\dot{x}(u)$, $\dot{y}(u)$, $\ddot{x}(u)$, $\ddot{y}(u)$ sırasıyla $x(u)$ ve $y(u)$ fonksiyonların birinci ve ikinci türevlerini belirtmektedir. Böylece denklem 3.8 ile parametrik gösterimli bir düzlemsel eğrinin, eğimini hesaplanabilecektir. Bu denklemlerin sadeleştirilmesi ile özel durum parametrizasyonları sağlanabilir [87]. Eğer yay uzunluğu w ile normalize edilirse (3.9)'daki bağıntı şöyle yazılabilir [85, 86, 89, 90].

$$k(w) = \dot{x}(w)\ddot{y}(w) - \ddot{x}(w)\dot{y}(w) \quad (3.9)$$

Böylece verilen düzlemsel bir eğri (3.10)'daki gibi yazılabilir [10,13,14].

$$\Gamma = \{x(w), y(w) \mid w \in [0,1]\} \quad (3.10)$$

Yay uzunluk parametresi w ile normalize edildiğinde, eğrinin evrimleşmiş versiyonu (3.11)'deki tanımlanır [88-90].

$$\Gamma_\sigma = \{X(u, \sigma), Y(u, \sigma) \mid u \in [0,1]\} \quad (3.11)$$

Böylece eğrinin evrimleşmiş koordinatları için denklem 3.12 yazılabilir [87].

$$\begin{aligned} X(u, \sigma) &= x(u, \sigma) * g(u, \sigma) \\ Y(u, \sigma) &= y(u, \sigma) * g(u, \sigma) \end{aligned} \quad (3.12)$$

Burada $*$ evrişimi ve $g(u, \sigma)$ Gauss fonksiyonunu göstermektedir. Gauss fonksiyonunun genişliği σ , [91]'deki çalışmaya göre tanımlanırsa;

$$g(u, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-u^2/2\sigma^2} \quad (3.13)$$

$X(u, \sigma)$ ve $Y(u, \sigma)$ bağıntıları denklem 3.13'e göre yeniden düzenlenirse;

$$\begin{aligned} X(u, \sigma) &= \int_{-\infty}^{\infty} x(v) \frac{1}{\sigma\sqrt{2\pi}} e^{-(u-v)^2/2\sigma^2} dv \\ Y(u, \sigma) &= \int_{-\infty}^{\infty} y(v) \frac{1}{\sigma\sqrt{2\pi}} e^{-(u-v)^2/2\sigma^2} dv \end{aligned} \quad (3.14)$$

Buna göre Γ_σ eğrisinin, κ eğriliği (3.14)'e göre yeniden düzenlendiğinde eğrilik için denklem 3.15 yazılır [86-88].

$$\kappa(u, \sigma) = \frac{X_u(u, \sigma)Y_{uu}(u, \sigma) - X_{uu}(u, \sigma)Y_u(u, \sigma)}{X_u(u, \sigma)^2 + Y_u(u, \sigma)^2}^{3/2} \quad (3.15)$$

Buna göre eğrinin $X(u, \sigma)$, $Y(u, \sigma)$ koordinat eksenleri yeniden düzenlenirse [89];


$$\begin{aligned} X_u(u, \sigma) &= \frac{\partial}{\partial u} x(u) * g(u, \sigma) = x(u) * g_u(u, \sigma) \\ X_{uu}(u, \sigma) &= \frac{\partial}{\partial u} x(u) * g(u, \sigma) = x(u) * g_{uu}(u, \sigma) \\ Y_u(u, \sigma) &= y(u) * g_u(u, \sigma) \\ Y_{uu}(u, \sigma) &= y(u) * g_{uu}(u, \sigma) \end{aligned} \quad (3.16)$$

olarak elde edilir. Sonuç olarak EÖU görüntünün sıfır geçiş noktalarındaki çok ölçekli sonuçlarının (I_c) gösterimi (3.17)'deki gibi yazılabilir [89].

$$I_c = (u, \sigma) | \kappa(u, \sigma) = 0, u \in 0, 1, \sigma \geq 0 \quad (3.17)$$


Son aşamada, EÖU görüntünün tüm sıfır geçiş noktalarında $\kappa(u, \sigma) = 0$ olarak tanımlanır. Sıfır geçiş noktalarındaki rotasyon, ötelenme ve ölçek sabittir. Çünkü eğrilik ancak farklı seviyeler için hesaplanabilmektedir [87]. Şekil 3.1'de görüldüğü gibi σ arttıkça Γ büzülür ve pürüzsüz hale gelir ve eğri üzerindeki sıfır geçiş noktalarının da sayısı

azalmaktadır. Sonunda eğri üzerinde herhangi bir sıfır geçiş noktası kalmadığında eğri konveks eğriye dönüşmüş olacaktır.



Şekil 3.1. Evrişime bağlı olarak eğrideki sıfır geçiş sayısının azalması [87]

Ayrıca EÖU, Şekil 3.2’de görüldüğü gibi ölçek, yönelim ve gürültü değişikliklerine dayanaklıdır. Çünkü afin uzunluğu yerine yay uzunluğu ile sınır parametrelendirme yapmaktadır [84-88].



Şekil 3.2. (a) EÖU görüntüsü ve sınırları, (b) EÖU dairesel kaymaya bağlı olarak yönelimi, (c) EÖU görüntüde gürültü etkisi [87]

3.1.2. Yönelim Ölçek Uzayı

EÖU gibi bazı öznitelik çıkarım yöntemleri genellikle eğri veya silüetlerin kenar noktalarının konveks kısımlarını kullanmaktadırlar [77-84]. Bazen üzerinde çalışılan silüetlerin kenar eğrileri keskin köşelere sahip olmayabilmektedirler. Bu nedenle son zamanlarda şekil iç sınırlarını dikkate alan silüetin parça yapılarının yakalanmasına yönelik yapılan çalışmalara artan bir ilgi olmuştur [77]. Bunlardan biri de Akagündüz'ün [77], Lowe [92], Mokhtarian ve Mackworth'un [78] çalışmalarından esinlenerek önerdiği değişmeyen silüet temsil dönüşümüne dayalı yöntemdir. Bu yöntemde, eğrinin Gauss Ölçek Uzayı (GÖU) oluşturularak her oktav düzeyi için yönelim vektörleri ve açıları ile Yönelim Ölçek Uzayı (YÖU) oluşturulur. Denklem 3.18 ile yönelim açıları $O(u)$ hesaplanabilir.

$$O(u) = \text{atan2}(\dot{x}(u), \dot{y}(u))$$

$$= \begin{cases} \arctan \frac{\dot{x}(u)}{\dot{y}(u)} & \dots \dots \dots \dot{x}(u) > 0 \\ \arctan \frac{\dot{x}(u)}{\dot{y}(u)} + \pi & \dots \dots \dots \dot{y}(u) \geq 0, \dot{x}(u) < 0 \\ \arctan \frac{\dot{x}(u)}{\dot{y}(u)} - \pi & \dots \dots \dots \dot{y}(u) < 0, \dot{x}(u) < 0 \\ + \frac{\pi}{2} & \dots \dots \dots \dot{y}(u) > 0, \dot{x}(u) = 0 \\ - \frac{\pi}{2} & \dots \dots \dots \dot{y}(u) < 0, \dot{x}(u) = 0 \\ \text{tanımsız} & \dots \dots \dots \dot{y}(u) = 0, \dot{x}(u) = 0 \end{cases} \quad (3.18)$$

Burada $\dot{x}$, $\dot{y}$ ve u eğrilik parametresi boyunca kapalı eğrinin x , y bileşenlerinin ilk türevlerini ve atan2, taban tabana zıt, yönleri ayırt edebilen ters tanjant fonksiyonun iki parametre değişikliği göstermektedir. YÖU derinlik görüntülerine uygulandığında, Silüet Yönelim Resmi (SYR) olarak adlandırılan genel tanımlayıcılar, eğri üzerindeki pozisyon ve tüm oktavların yönelim vektörlerini oluşturulabilmektedir.

SYR, eğri üzerindeki başlangıç noktasından bağımsız eşleşen ve düzlemsel dönme altında dönüştürülebilen kapalı düzlemsel eğriler için genel bir gösterim olup ölçek değişiminden etkilenmemektedir. Temel olarak ölçek uzayında eğrinin yönelim gösterimi olarak da belirtilebilir. SYR eğrinin, YÖU ve Morfolojik Ölçek Uzayı (MÖU) değerlerinin her ikisini de kullanarak düşük hacimli bir 2B'li ölçek uzayı oluşturabilmektedir. Başka bir

deyişle MÖU, eğri ve YÖU olmak üzere üç eksenli bir hacimsel renk tanımlayıcısıdır [77]. SYR tanımlayıcısını oluşturmak için öncelikle eğri zincir kodları kullanılarak alt piksel koordinatları ile örneklenir. Böylece doğrusal alt piksel koordinatları, eğrinin eşit uzunluktaki yayları içinde düzgün olmayan biçimde örneklenmiş olmaktadır [77].


Eğrinin örneklenmesinden sonra her yayın yönelimi farklı ölçekler için hesaplanır. Bir eğrinin ölçek uzayı $L(u, \sigma)$ Denklem 3.19'daki gibi tanımlanabilir.

$$L(u, k\sigma) = g(u, k\sigma) * r(u) \quad (3.19)$$

Burada $L(u, k\sigma)$, $r(u)$ parametrik eğri ile [92]'deki ölçek parametresi k , σ standart sapma ve değişken ölçekli $g(u, k\sigma)$ Gauss fonksiyon evrişimidir. Benzer şekilde $O(u, \sigma)$ YÖU (3.20)'deki gibi tanımlanabilir;

$$O(u, k\sigma) = \text{atan2}(g(u, k\sigma) * \dot{x}(u), g(u, \sigma) * \dot{y}(u)) \quad (3.20)$$

Her SYR içindeki piksel konumları, yönelim açıları renk gösterimleri ölçek ve pozisyonlarını göstermektedir. Şekil 3.3'te bir silüetin yönelim açısına göre dikdörtgensel ve radyal renk dağılımı görülmektedir. Dikdörtgenin yatay eksen oryantasyon vektörlerin parametrik pozisyonlarını vermektedir. Eğer eğriyi kapalı kabul edersek, r $[0,1]$ değişkeni ile parametrelendirilir, oryantasyon vektörlerinin pozisyonu yatay eksen boyunca dağıtılır. Dikdörtgenin dikey eksen ise ölçek seviyelerini temsil etmektedir [77].



Şekil 3.3. Bir silüetin yönelim açısına göre dikdörtgensel ve radyal renk dağılımı [77]

3.2. Öznitelik Kodlama Yöntemleri

Kodlama, özellikleri tanımlayan vektörler içerisine bir takım değerleri atama veya görsel kelimelerin uzamsal histogramlarını oluşturma eylemidir. Kodlanmış kelimeler bilgi kodlama stratejisine bağlı olarak genellikle bilgi kaybını en aza indirmek için kullanılır. Kodlama stratejisi en uygun kodlu kelimenin seçiminin azalması sınıflandırma performans dönüşümü, daha az ayırt etme gücüne sahip kodlu tanımlayıcılara neden olacaktır. Bu sebeple son yıllarda orijinal görüntü özellikleri hakkında daha fazla bilginin korunması amacıyla FV, KÇ gibi alternatif kodlama yöntemleri geliştirilmiştir. Tez çalışmasının bu alt bölümünde, bu yöntemler incelenmiştir.

3.2.1. Fisher Vektör

$X = \{x_t, t=1, \dots, T\}$ şeklinde görüntülerden çıkarılmış yerel tanımlayıcılar kümesidir. X 'in üretim süreci λ Gauss parametreleri ile bir O_{λ} olasılık yoğunluk fonksiyonun modellenebileceği kabul edilir [93, 94]. Bu durumda, X 'in gradyant vektörü aşağıdaki gibi tanımlanabilir [94]:

$$G_{\lambda}^x = \frac{1}{T} \nabla_{\lambda} \log_{u_{\lambda}}(X) \quad (3.21)$$

λ parametrelerinin sayısı bu vektör boyutu ve vektör boyutundan etkilenmeyen yamaların sayısı ile hesaplanır. Bu gradyantların çekirdeği K [94];

$$K(X, Y) = G_{\lambda}^{x'} F_{\lambda}^{-1} G_{\lambda}^y \quad (3.22)$$

formülü ile tanımlanır. Burada F_{λ} , u_{λ} 'nin bilgi matrisidir.

$$F_{\lambda} = E_{x \sim u_{\lambda}} [\nabla_{\lambda} \log_{u_{\lambda}}(x) \log_{u_{\lambda}}(x)'] \quad (3.23)$$

$F_{\lambda} = L_{\lambda} L_{\lambda}'$ ve $K(X, Y)$ Choleskey ayrışma kullanılarak aşağıdaki gibi yazılabilir:

$$g_{\lambda}^x = L_{\lambda} G_{\lambda}^y \quad (3.24)$$

g_{λ}^x , X 'in Fisher vektörüdür. Olasılık yoğunluk fonksiyonunun u_{λ} Adaptif Gauss Karışım Modeli (AGKM) ile modellendiği kabul edilir. Böylece;

$$u_{\lambda}(x) = \sum_{i=1}^K w_i u_i \quad (3.25)$$


$$\lambda = \{w_i, \mu_i, \Sigma_i, i=1, \dots, K\}$$

$u_{\lambda}(x) = \sum_{i=1}^K w_i u_i$ biçiminde yazılabilir ve w_i, μ_i, Σ_i Gauss dağılım işlevi u_i 'nin parametreleridir.

3.2.2. Kelime Çantası


KÇ, bilginin alınması ve doğal dil işleme yönteminin basit gösterim biçimi olup, KÇ terimi kelimelerin sırasız dizileri olarak dikkate alınan dokümanlardaki bu yaklaşımdan esinlenen belge sınıflandırma teknikleri anlamına gelmektedir. Bu yöntemde, bir doküman veya cümledeki bir kelimenin dilbilgisi ve hatta sırası dikkate alınmadan sadece kelimenin kullanım sıklığı ile bir çanta içerisinde temsil edilmesine dayanmaktadır. Verilen metinde ayırt edici bilgilerin çoğu her kelimenin cümlede bulunma sayısı sayılarak elde edilebilir. Sözcük sayımı teknik ve teknik olmayan metinler arasındaki ayrımın yapılması, konunun sınıflandırılmasını da sağlamaktadır. Bunu en iyi, e-postalarımızda gelen postanın önemsiz (spam) ve önemli olması arasında karar verilmesinde görebilmekteyiz.

Son zamanlarda KÇ yöntemi bilgisayarlı görmede de yaygın olarak kullanılmaya başlanmıştır [95]. Bir görüntünün yerel özellikleri görsel kelimeler olup, bu görsel kelimeler daha sonra çantalama ile (yerel özellik havuzu) tüm boyutsal yapının ayrımı yapılır ve son olarak yerel özellik pencerelerinin ortalama birleşimi ile görsel sınıflandırılır. Görüntü işlemede kullanılan kelimeler yerel görüntü özelliklerini temsil etmişlerdir. Bu özellikler ölçek uzayı ekstremum noktaları gibi ilgili noktaları etrafında oluşturulabilir veya sadece düzenli pozisyonlar ve çeşitli ölçeklerdeki görüntülerden çıkarılan basit pencerelerdir [96, 97]. Şekil 3.4'te görüldüğü gibi sürecin etkin bir şekilde görselleştirilmesi amacıyla ortaya çıkan gösterim Görsel Kelime Çantası (GKÇ) modeli olarak adlandırılmıştır [95].



Şekil 3.4. GKÇ modeli [98]


Şekil 3.5’te GKÇ aşamaları görülmektedir [99]. İlk olarak görüntü temsili için yerel özellikler çıkarımı yapılmaktadır. Bu özellikler, sadece görüntünün düzenli pozisyonlar ve çeşitli ölçeklerdeki görüntülerden çıkarılan basit pencereler şeklinde olabilmektedirler. Görüntünün simgelenmesi kodlama ve birleştirme (havuzlama) olmak üzere iki aşamadan oluşmaktadır.



Şekil 3.5. GKÇ’nin oluşturulması [99]

Kodlama, kelimelerin yerel özellikleri ile kelimelerin şifrelenmesi ve kelimedeki özelliklerin cevabının oluşturulması anlamına gelmektedir. Bu işlem için genellikle olasılıksal stratejiler kullanılmaktadır. Ancak son zamanlarda yüksek performanslı bazı yüksek boyutlu kodlama yöntemleri ile elde edilmektedir [99-102]. Yüksek boyutlu kodlamavektörleri doğrudan kelime olarak kullanılmazlar, ancak k-ortalama gibi vektör niceleme teknikleri kullanılmaktadır [98]. Birleştirme işleminde ise yeni görüntü kelimesi nicelenmiş kelimeler ile birleştirilerek sınıflandırıcıya uygulanmaktadır. Kısaca KÇ, verilen özellik kümesinin frekans histogramlarını oluşturur. Diğer bir deyişle atama dizinlerini kullanarak verilen tanımlama seti için bir frekans histogramı oluşturulmasıdır. Ardından histogram normalize edilir ve bu histogramı oluşturulan sözlük ile aynı boyutadır. KÇ

kodlama örneği görülen Şekil 3.6.(a)'da veri kümesindeki farklı üç resim, Şekil 3.6.(b)'de a'daki görüntülerden çıkartılmış tanımlayıcılar, Şekil 3.6.(c)'de (b)'deki tanımlayıcılardan öğrenilmiş sözlükler ve Şekil 3.6.(d)'de ise her görüntünün frekans histogramı görülmektedir.



Şekil 3.6. KÇ Kodlama örneği; (a) veri kümesi görüntüleri; (b) görüntülerden çıkartılmış tanımlayıcılar; (c) öğrenilmiş sözlükler; (d) frekans histogramları [98]


3.3. Sınıflandırma Yöntemleri

Sınıflandırma verilerin veya özniteliklerin içerdiği ortak özelliklere göre ayrıştırılması işlemidir. Sınıflandırmanın temel yapısı bir öğrenme algoritmasına dayanmaktadır. Bu öğrenme algoritması, herhangi yeni bir özniteliğin veya verinin, bilinen özelliklere göre herhangi bir gruba atanmasını sağlamaktadır. Tez çalışmasının bu alt bölümünde yukarıda açıklanan öznitelik çıkarım ve kodlama algoritmalarından alınan

özniteliklerin gruplandırılması için kullanılan DVM, k-EYK ve Naive Bayes gibi sınıflandırıcılar incelenmiştir.

3.3.1. Destek Vektör Makinası


DVM örüntü tanımada çok yaygın olarak kullanılan bir yöntemdir. DVM algoritmaları başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmış olmakla birlikte daha sonra hem çok sınıflı hem de doğrusal olmayan veri sınıflandırmaları için de kullanılmaya başlanmıştır. Temel çalışma prensibi Şekil 3.7’de görülen iki sınıflı veriye ait bir kümeyi ayıran ve en uygun (optimal) hiper düzlemin bulunmasına dayanmaktadır [103]. Şekil 3.7’de de görüldüğü gibi bu iki sınıflı veriyi birbirinden ayırabilecek birçok hiper düzlem bulunmaktadır. Burada önemli olan hangi hiper düzlemin kullanılabileceğini bulabilmektir [103-105].



Şekil 3.7. İki sınıflı veriyi ayırabilen hiper düzlemler


DVM’nin l sayıda örnekten oluşan $\{x_i, y_i\}, i = 1, \dots, l, y_i \in \{-1, 1\}, x_i \in R^d$ biçiminde eğitim verisinin olduğunu kabul edelim. Burada x_i özellik vektörünü ve y_i sınıf etiketlerini belirtmektedir. Burada vektörler kümesini birbirinden ayıracak birçok hiper düzlem bulunmakla birlikte birbirine en uzak olan hiper düzlemleri seçmek en etkili yaklaşımdır [103-105]. Bunun için Şekil 3.8’de olduğu gibi kırmızı kareler ve yeşil dairelerden oluşan veri kümesini birbirinden ayırmak için, birbirine en yakın olan yeşil daireler ve kırmızı

kareleri doğrusal olarak ayıracak alt hiper düzlemlerin belirlenir ve bu alt hiper düzlemler arasındaki uzaklığın maksimum olması gerektiği unutulmamalıdır.



Şekil 3.8. İki sınıflı verideki alt hiper düzlemler

Daha sonra şekil 3.9’da görüldüğü gibi bu iki alt düzleme eşit uzaklıklardaki ayırımı yapacak optimal hiper düzlem çizilir. Bu düzlem için (3.26) yazılabilir [103-105].



Şekil 3.9. İki sınıflı veriyi optimal ayıran hiper düzlem

$$H_0 = w^T x + b = 0$$

$$H_0 = \sum_{i=1}^l w_i x_i + b = 0$$

(3.26)

Burada $w = \{w_1, w_2, \dots, w_l\}$ ağırlık vektörünü, l nitelik vektörünü ve b ise sabit sayısı göstermektedir. Bu hiper düzlemleri bulabilmek için $w \cdot x + b = 0$ temel bağıntısı kullanılmakta, w hiper düzlem dik doğruyu, b ise sabit bir değerdir. Hiper düzlemin orijine olan uzaklığı $|b| / \|w\|$ ile, $\|w\|$ ise Öklid bağıntısı ile hesaplanmaktadır. Aynı şekilde H_1 ve H_2 alt hiper düzlemleri için sırasıyla denklem 3.27 ve 3.28 yazılabilir [103-105];

$$H_1 = w^T x + b = -1 \quad (3.27)$$

$$H_2 = w^T x + b = 1 \quad (3.28)$$

Ayrıca H_1 düzleminin altında ve H_2 düzleminin üstünde kalan noktalar için sırasıyla (3.29) ve (3.30) yazılabilir [103-105];

$$w^T x + b \leq -1 \text{ için } y_i = -1 \quad (3.29)$$

$$w^T x + b \geq 1 \text{ için } y_i = 1 \quad (3.30)$$

Yukarıdaki denklem 3.29 ve 3.30 düzenlenerek tek bir bağıntı olarak (3.31)'deki gibi yazılabilir [103-105];

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall_i \quad (3.31)$$

H_1 ve H_2 alt hiper düzlemler arasındaki maksimum uzaklık (m) denklem 3.32 ile bulunabilir;


$$m = 2 \frac{|w^T x + b|}{\|w\|} = \frac{2}{\|w\|} \quad (3.32)$$

Buraya kadar herhangi veri kümesinin doğrusal bir hiper düzlem ile iki sınıfa nasıl ayrılabilirdiğini gördük. Bazen Şekil 3.10'da görüldüğü gibi veri kümeleri yukarıdaki gibi doğrusal olarak ayırmak mümkün olmayabilmektedir. Bu durumda pozitif ve hataları tanımlayan ζ gevşeklik değişkenlerinin denklem 3.31'e eklenerek yazılabilecek denklem 3.33 yardımıyla çözüm bulunur.

$$y_i(x_i \cdot w + b) \geq 1 - \zeta_i, \zeta_i \geq 0 \quad \forall_i \quad (3.33)$$

Bu durumda optimal hiper düzlemi bulmak için Denklem 3.33'deki amaç fonksiyonunu minimize ettiğimizde ceza parametresi (C) dahil olmaktadır. Buna göre amaç fonksiyonu (3.34)'teki gibi yazılabilir [106];

$$L(w, \zeta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \zeta_i \quad (3.34)$$



Şekil 3.10. Doğrusal olmayan verilerin doğrusal hiper düzlem ile ayrılması

3.3.2. Naïve Bayes Sınıflandırma

Bayes sınıflandırma, Bayes karar kuralına göre sonraki olasılık değerlerini hesaplamak için önceki olasılıkları kullanan ve temel olasılık modeli olarak da kabul edilen bir denetimli istatistiksel öğrenme yöntemidir [107]. Verilen bir sınıf değişkeni c ve özellik vektörü $x \in R_n$ Bayes karar kuralı olarak tanımlanırsa;

$$P(c|x_1, \dots, x_n) = \frac{P(c)P(x_1, \dots, x_n|c)}{P(x_1, \dots, x_n)} \quad (3.35)$$

Naïve bağımsızlık varsayımı kullanıldığında

$$P(c|x_1, \dots, x_{i-1}, \dots, x_n) = P(x_i|c) \quad (3.36)$$

tüm i değerleri için denklem 3.36 basitleştirebilir;

$$P(c|x_1, \dots, x_n) = \frac{P(c) \prod_{i=1}^n P(x_i|c)}{P(x_1, \dots, x_n)} \quad (3.37)$$

Çünkü $P(x_1, \dots, x_n)$ için verilen giriş sabittir. Bundan dolayı aşağıdaki sınıflandırma kuralını kullanabiliriz;

$$P(c|x_1, \dots, x_n) \approx P(c) \prod_{i=1}^n P(x_i|c) \quad (3.38)$$

En yüksek olasılıkla $\hat{c}$ sınıfı denklem 3.39'daki tanıma sonucuna göre seçilir.

$$\hat{c} = \arg \max_c P(c) \prod_{i=1}^n P(x_i|c) \quad (3.39)$$

3.3.3. k-En Yakın Komşu Algoritması ile Sınıflandırma

Bu algoritma en klasik örüntü tanıma yöntemlerinden biridir. Sınıfların olasılık dağılımlarına ihtiyaç duyulmadan sınıflandırma yapılmasını sağlayan örüntü sınıflandırıcıdır. Sınıflandırmayı k değerine bağlı olarak yapmaktadır. Test edilecek veri, eğitim kümesindeki verilerin her birine olan uzaklığını hesapladıktan sonra sınıfı bilinen en yakın komşuların k tanesi olarak seçilir. Daha sonra eğitim verilerinden kendisine en yakın olana atanır [108]. Uzaklık hesaplamasında çoğunlukla Oklid $\sqrt{\sum_{i=1}^k (x_i - y_i)^2}$ yöntemi kullanılmakla birlikte Minkowski $(\sum_{i=1}^k (|x_i - y_i|^q))^{1/q}$ ve Manhattan $\sum_{i=1}^k |x_i - y_i|$ yöntemleri de kullanılabilmektedir.

4. FUKINECT – DÜŞME VERİ SETİNİN OLUŞTURULMASI

4.1. Giriş

Görüntü tabanlı düşme tespit sistemlerinde tüm araştırmacıların kullanımına açık 5 veri seti bulunmaktadır [109]. Bu veri setlerinin üçünde Kinect® kamera, birinde tekli KYM kamera ve diğerinde ise kalibre edilmiş çoklu KYM kameralar kullanılmıştır. Araştırmacılar, 2010 yılından sonra düşme tespitine yönelik yapılan görüntü tabanlı çalışmalarda, Bölüm 2’de belirtilen avantajları nedeniyle derinlik kameralarını daha yoğun olarak kullanmaya başlamışlardır. Bu nedenle, bu bölümde öncelikle Kinect® kameranın yapısı ve özellikleri kısaca tanıtıldıktan sonra Kinect® kullanılarak oluşturulan veri seti içerikleri hakkında kısa bir bilgilendirme yapılacaktır. Ayrıca bu tez çalışması için oluşturulan FUKinect-Fall veri setinin oluşturulması detaylandırılacaktır.

4.2. Microsoft Kinect® Kamera


Kinect®, renkli ve derinlik görüntülerini eşzamanlı sağlayan bir Kırmızı Yeşil Mavi-Derinlik (KYM-D) algılayıcıdır [110, 111]. 2010 yılında piyasa sürülmüş ve herhangi bir kumanda veya kontrol çubuğu kullanmadan başlangıçta sadece el hareketleri ile oyun oynamayı sağlayan bir oyun konsolunun ünitesi olarak üretilmiştir. 3B insan hareketi algılama algoritmasıyla, kullanıcılar ve oyunlar arasında kumanda olmadan etkileşime imkân sağlamaktadır [110]. Şekil 4.1’deki Kinect® aynı zamanda Xbox 360 olarak da adlandırılan oyun konsolunun temel bir parçasıdır.



Şekil 4.1. Kinect® kamera görseli

Kinect® donanımsal olarak bir mikrofon dizisi, yapılandırılmış ışık kullanarak etkin bir algılama yeteneğine sahip derinlik kamerası ve bir de renkli kameraya sahiptir [111].

Ayrıca Şekil 4.2’deki donanımsal yapısında da görüldüğü üzere yatay ve dikey yönde hareketini sağlayan eğim motoru ve derinlik bilgisinin hesaplanmasını sağlayacak olan bir kızılötesi ışık kaynağı da bulunmaktadır. Renkli kamera, 640×480 piksel çözünürlüğünde ve saniyede 30 çerçeveli görüntü vermektedir. Buna karşın derinlik kamerası, kızılötesi ışık kaynağının gönderdiği ışınların geliş gidiş sürelerini hesaplayarak 320×240 piksel çözünürlükte ve saniyede 30 çerçeveli görüntü verebilmektedir [110-113].



Şekil 4.2. Kinect® donanımsal yapısı


Kinect® tabanlı bilgisayar görmesi konuları dört ana başlıkta ele alınabilir [112]. Bunlar; nesne izleme ve tanıma, insan aktivite analizi, el hareketi analizi ve bina içi 3B haritalamadır. İnsan eylemlerinin ve hareketlerinin tanınması kayda değer bir ilgi alanıdır ve son yirmi yılda yaygın olarak çalışılan bir araştırma konusu olmuştur [112]. Bu alandaki genel amaç, çeşitli insan aktivite ve eylemlerinin otomatik analizini sağlamaktır. Video, hareket algılama, derinlik verisi veya bunların birleşimiyle birçok eylem ve hareket tanıma yöntemi geliştirilmiştir ve gözetleme, insan-bilgisayar etkileşimi, bilgisayar oyunları ve işaret dili analizi gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır.

4.3. Kinect® Donanım Özellikleri

4.3.1. Kinect® Görmesi


Kinect® çok yönlü bir kameradır. Tüm vücut hareketlerini görebilmesinin yanı sıra küçük el hareketlerini de görebilmektedir. Ancak Kinect® de sensörlerden oluşmuştur ve sensörlerin sınırları ve insanların en iyi etkileşimi tecrübe ettikleri alanları mevcuttur [111]. Kinect® görmesine ait bazı temel özellikler aşağıda detaylandırılmıştır.

Vücut takibi (izleme) mesafesi: Kinect® insan vücudu takibi için Şekil 4.3'te görülen fiziksel sınır olarak 0,8m ile 4m arasında, etkili nokta olarak 1,2m ile 3,5m arasında çalışabilmektedir [111].




Şekil 4.3. Kinect® vücut takibi mesafesi [111]

Derinlik görüş açısı: Kinect® derinlik sensörünün Şekil 4.4'te görüldüğü gibi yatay olarak 57,5°, dikey olarak 43,5° görüş açısı vardır. Ayrıca eğim motoru, -27 ° ve +27 ° açı aralığında kameraları aşağı yukarı doğru hareket ettirilebilir [110-113].




Şekil 4.4. Kinect® derinlik görüş açısı [111]

İskelet izleme: Şekil 4.5’te görüldüğü gibi Kinect® altı kişiye kadar iskelet izleme yapabilmektedir. Bütün iskelette 20 eklemi inceleyebilmektedir [111].



Şekil 4.5. İskelet izleme [111]

Tam iskelet kipi: Kinect® varsayılan olarak tam iskelet modunda Şekil 4.6’da görüldüğü gibi 20 eklemi izleyebilmektedir [111, 113].



Şekil 4.6. Tam iskelet kipi [111]

Oturma kipi: Kinect® oturmuş iskeletlerde de Şekil 4.7’de görüldüğü gibi 10 eklemi izleyebilmektedir [111, 113].




Şekil 4.7. Oturma kipi [111]

4.3.2. Kinect® Duyması


Kinect® tek sensörle hem sesi hem de hareketleri algılayabildiğinden eşsizdir. Uygulamalarda hareketlere cevap vermesinin yanında sözel girdilere de cevap vermesi için Kinect®’te dört adet mikrofon bulunmaktadır [110, 113]. Kinect duymasına ait bazı temel özellikler aşağıda detaylandırılmıştır.

Ses girişi: Kinect® ön taraftan gelen sesleri Şekil 4.8’de görüldüğü gibi $\pm 50^\circ$ de algılamaktadır [111].




Şekil 4.8. Ses girişi [111]

Mikrofon dizisi: Mikrofon dizisi Şekil 4.9’de görüldüğü gibi 100° lik aralık içinde 10° lik adımlarla işaret edebilmektedir. Bu özellik önemli seslerin yönleriyle ilgili kullanılabilir [5].




Şekil 4.9. Mikrofon dizisi [111]

Ses eşiği: Mikrofon dizisi Şekil 4.10’da görüldüğü gibi 20 dB (desibel) ortam gürültüsünü engelleyebilmektedir, bu ses kalitesinin iyileşmesini sağlar [111].




Şekil 4.10. Ses eşiği [111]

Yöneltilmeli mikrofon: Ayrıca Şekil 4.11’de görüldüğü gibi mikrofon dizisi programlamayla yönlendirilebilir [111].



Şekil 4.11. Yöneltilmeli mikrofon [111]

Yüksek ses kaynağını hedefleme: Şekil 4.12’de görüldüğü gibi Kinect® en yüksek ses girişini izler [110-113].



Şekil 4.12. Yüksek ses kaynağı hedefleme [111]

4.3. Yazılım Geliştirme Kiti

Yazılım Geliştirme Kiti (YGK), sensörlerden gelen ham veriyi işlemektedir. Altı kişiye kadar iskelet takibi (izleme) bilgisini sağlamak için sensörlerden gelen verinin işlenmesi ayrıca ses verisinden belirlenen dil için kelime tanınması örnek olarak gösterilebilir [112]. YGK aynı zamanda YGK'nın ve bileşenlerinin özelliklerinin nasıl kullanılacağını gösteren kod örnekleri içermektedir. Bu örnek kodlar hem pratik hem de analitik sebepler için uygulamalar geliştirilebilmesi açısından oldukça yararlıdır [110-113].

4.4. Mevcut Düşme Veri Setleri

Literatürde düşme tespit çalışmalarında Kinect® kamera ile oluşturulan birçok veri seti olmasına rağmen araştırmacıların kullanımına sunulan SDUFALL [114], EDF [115] ve OCCU [116] veri seti özellikleri anlatılacaktır. EDF ve OCCU veri setleri tez çalışmasında kullanılmamış olup sadece bu alanda çalışacak araştırmacıların destek sağlanması amaçlanmıştır. Ayrıca tez çalışmasında önerilen FV Kodlama, SYH ve Eklem tabanlı düşme tespit yöntemleri etkinliğinin test edilmesi için klasik KYM kamere kullanılan MultiCam [117], Wiezmann [118] ve düşme eylemleri içermeyen Kinect ile oluşturulan UTKinect-Action [119] veri setleri eylem özelliklerine yer verilmiştir.

4.4.1. SDUFALL Veri Seti

Veri seti için tek Kinect® kamera kullanılmış ve Kinect® yerden 1,5m yüksekliğe yerleştirilmiştir. Veri setinin oluşturulmasında 20 genç erkek ve bayan denek yer almıştır. Veri seti yürüme, eğilme, oturma, çömelme, uzanma ve düşme eylemlerini içermektedir. Farklı şartlardaki eylemleri yakalamak için derinlik videoları aşağıdaki senaryo dahilinde; bir nesneyi taşımak yada taşımamak, çekim yapılan ortamın ışığı açık yada kapalı, ortam düzenini değiştirerek, kamera konumu yada kamera ile ilgili pozisyonları değiştirerek kaydedilmiştir. Her bir eylem büyük bir nesneyi taşıma, taşımama, ışıқта, karanlıkta, kamera pozisyonunun ve yönünün değiştirilmesini gibi belli şartlar altında gerçekleştirilmiştir. Ayrıca her bir eylem 10'ar kez tekrar edilmiş olup toplamda 6 eylem $\times$ 20 kişi $\times$ 10 tekrar = 1200 renkli video (.avi), derinlik video (.avi) ve 20 iskelet eklemin pozisyonları (.txt) olmak üzere üç ayrı veri toplanmıştır. Tüm derinlik videolar 320 $\times$ 240 çözünürlükte, avi formatında

ve saniyede 30 çerçeve olarak kaydedilmiştir. Şekil 4.13'te veri setindeki 6 eyleme ait bazı derinlik videoları görülmektedir. Veri seti ile ilgili daha detaylı bilgi için, [114]'deki internet adresinden ulaşılabilir.




Şekil 4.13. SDUFALL veri seti düşme eyleminin silüet görüntüler [114]

4.4.2. EDF Veri Seti

Veri setinin oluşturulmasında iki Kinect® kamera ve kayıt için Microsoft YGK ve C# programları kullanılmıştır. Kameralar, laboratuvar ortamında modellenen yaşlı yaşam alanının farklı iki köşesine yerleştirilmiştir. Böylece aynı anda iki bakış noktası ile veriler eş zamanlı olarak kaydedilmiştir. Veri seti çalışmaları Kinect® kameranın etkin görüş mesafesi olan 0,5 – 4,5 m arasındaki bir alanda gerçekleştirilmiştir. EDF veri setinde 8 düşme yönü belirlenmiş olup ve her bir bakış açısı ile iki düşme eylemi 10 farklı şekilde gerçekleştirilmiştir. Bu nedenle her bir bakış açısında 160 adet olmak üzere toplamda 320 adet düşme eylemi bulunmaktadır. Şekil 4.14'te EDF veri setindeki farklı bakış açıları ile düşme eylemine ait renkli ve silüet görüntüler görülmektedir.

EDF veri seti içeriğinde 20 örnekte bir nesneyi zeminden alma, 20 örnekte zeminde oturmak, 20 örnekte zemine uzanmak, 20 örnekte ayakkabı bağı bağlamak ve 20 örnekte zeminden destek alınarak eksersiz yapma olmak üzere düşme durumuna benzer özellikleri

üretime eğiliminde olan toplam 100 eylem gerçekleştirilmiştir. Veri seti içeriği saniyede 25 çerçeve olmak üzere 320×240 piksel çözünürlükte kaydedilmiştir. Veri setine [115]'deki internet adresinden ulaşılabilir.




Şekil 4.14. EDF veri seti düşme eyleminin renkli ve silüet görüntüler [109]


4.4.3. OCCU Veri Seti

Bir önceki veri setinde olduğu gibi bu veri setinde de iki Kinect® derinlik kamerası modellenen yaşam alanının farklı iki köşesine yerleştirilmiştir. Diğer veri setlerinden farklı olarak bu veri setinde kişi düşme öncesi düşme eylemleri boyunca yatak, kanep ve masa gibi herhangi bir nesne ile %25, %50 ve %75 oranlarda engellenerek ile düşme eylemi sonlandırılmaktadır. Veri setinin oluşturulmasında 5 denek yer almıştır. OCCU veri setinde her bir bakış açısı ile 6 düşme gerçekleştirilmiştir. Her bir kameranın bakış açısı ile 30'ar adet düşme eylemi gerçekleştirilmiştir. Her bir bakış açısı diğer bakış açısından farklı zamanlarda kaydedilmiş ve böylece her iki bakış açısı ile eşzamanlı olarak kaydedilmiş aynı olaylara sahip değildir. Veri seti içeriğinde hepsi düşme eğiliminde olan 20 örnekte bir nesneyi zeminden almak, 20 örnekte zeminde oturmak, 20 örnekte ayakkabı bağlamak ve 20


örnekte zeminde uzanma olmak üzere toplamda 80 eylemi içermektedir. Şekil 4.15'te her bir bakış açısından ve belirli oranlarda engellenmiş düşme benzeri eylemler görülmektedir. Veri setine ait daha detaylı bilgi ve veri seti içeriğine [116]'daki internet adresinden ulaşılabilir.



(a)



(b)



(c)

Şekil 4.15. Belirli oranlarda engellenmiş düşme eylem örnekleri; (a) İki farklı bakış açılı ve %25 engellenmiş düşme eylem örnekleri, (b) İki farklı bakış açılı ve %50 engellenmiş düşme eylem örnekleri, (c) İki farklı bakış açılı ve %75 engellenmiş düşme eylem örnekleri

4.4.4. MultiCam Veri Seti

Veri setinin oluşturulmasında çoklu BASLER A312fc kamera ve kayıt için Matlab programı kullanılmıştır. Kameralar, 3,5m×3m×4,5m boyutlarındaki laboratuvar ortamında modellenen akıllı odanın tavanında farklı bölgelere yerleştirilmiştir. Böylece aynı anda farklı bakış noktası ile veriler eş zamanlı olarak kaydedilmiştir. MultiCam veri setinde toplamda 24 senaryo bulunmaktadır. İlk 22 senaryo düşme eylemini ve geri kalan iki senaryo da çömelleme, oturma eylemlerini içermektedir. Veri setine [117]'deki internet adresinden ulaşılabilir.

4.4.5. Wiezmann Veri Seti

Veri setinin oluşturulmasında sekiz IP kamera kullanılmıştır. Kameralar 4,7m×2,8m×9m boyutlarındaki modellenen odanın tavanında farklı bölgelere yerleştirilmiştir. Veri seti, el sallamak, koşma, koşuşturmak, atlama, sıçrama, eğilme ve yürüme gibi 10 farklı eylemi içermektedir. Veri setine [118]'deki internet adresinden ulaşılabilir.

4.4.6. UTKinect-Action Veri Seti

Veri seti; *yürüme, ayakta durma, oturma, yerden bir şey alma, taşıma, fırlatma, itme, çekme, iki elle dalga hareketi ve alkışlama* olmak üzere 10 eylemden oluşmakta ve bazı eylemlere ait KYM ve derinlik görüntüleri Şekil 4.16’da görülmektedir. Bu eylemler bir sabit Kinect kamera ile iç mekan ortamında gerçekleştirilmiş ve saniyede 30 resim alınarak çekilmiştir. RGB resimlerinin çözünürlüğü 640×480 ve derinlik resimlerinin çözünürlüğü 320×240’tır. RGB resimleri sadece gösterim amaçlıdır ve çalışmada kullanılmamıştır. Biri bayan dokuzu bay toplam 10 kişi tarafından her bir eylem iki kez tekrarlanmıştır. Ayrıca kişilerden bir tanesi de solaktır. Aynı eylemin kişiler tarafından farklı şekilde gerçekleştirilmesi ve eylem çerçeve uzunluklarının değişkenlik göstermesi gibi nedenlerle *UTKinect-Action* zorlayıcı bir veri setidir. Veri setine [119]’daki internet adresinden ulaşılabilir.



Şekil 4.16. Veri setindeki bazı eylemlerin KYM ve derinlik görüntüleri [120]

4.5. FUKinect – Fall Veri Seti


FUKinect-Fall veri seti tez çalışmasında kullanılmak üzere hazırlanmıştır.

4.5.1 Deney Alanının Oluřturulması

Veri setinin oluřturulması iin Fırat niversitesi Teknoloji Fakltesi Elektrik Elektronik Mhendislięi Kontrol laboratuvarında Őekil 4.17’de grlen deney alanı oluřturulmuřtur. Kinect® kamera deney alanının orta merkezini karřılayacak řekilde yerden 95cm ykseklikte ayaklı kamera sehpası zerine yerleřtirilmiřtir. Kinect’in grme sınırları olan 0,5m ile 4,5m referans alınarak 4×4m’lik bir alan ve derinlik sensrnn dikey, yatay grř aılları dikkate alınarak Őekil 4.18’deki alıřma alanı oluřturulmuřtur. Ayrıca veri setinin oluřturulmasında grev alan deneklerin boy, kilo gibi fiziksel zellikleri ve yapılan eylem trne baęlı olarak eylemler 2m ile 3,5m arasındaki alanda gerekleřtirilmiřtir.



Őekil 4.17. Veri seti deney alanı




Şekil 4.18. Veri seti çalışma alanı

4.5.2 Veri Setinin Oluşturulması


Veri setinin oluşturulması için Kinect® ve Matlab 2014a programı kullanılmıştır. Matlab 2014a'da doğrudan ara bağlantı ile Kinect® görüntülerini bilgisayar ortamına aktarılmasını sağlayan görüntü edinme araç çubuğu (Image Acquisition Toolbox) bulunmaktadır. Veri toplama işleminin başlangıç aşamasında Kinect® görme sınırları içerisindeki kişi algılandığı anda Kinect® otomatik olarak kendisini kalibre ettikten sonra kayıt işlemine başlamaktadır.

Veri seti, 19-72 yaş arasındaki 21 denek tarafından *yürüme*, *eğilme*, *oturma*, *çömelme*, *uzanma* ve *düşme* eylemleri sırası ile yapılmıştır. Her bir eylem Şekil 4.17'deki sıraya göre 8'er kez tekrar edilmiştir. Şekil 4.19'da görüldüğü gibi 1-4, 2-3, 5-6 numaralı eylemler karşılıklı olarak ve 7-8 numaralı eylemler aynı noktada başlamakta, çalışma alanı orta noktasından sonra zıt yönlerde doğru hareket ile gerçekleştirilmiştir. Bütün eylemlerde belirli bir mesafe yürümeden sonra (2-3 adım) *eğilme*, *oturma*, *çömelme*, *uzanma* ve *düşme* eylemleri yapılmıştır. Veri setinde toplamda (6 eylem $\times$ 8 tekrar $\times$ 21 denek) 1008 derinlik videosu ve Şekil 4.20'de eklemleri numaralandırılmış iskelet yapısındaki 20 eklem her birinin 3B koordinatlar (x, y, z) .mat uzantılı Matlab dosyası olarak kaydedilmiştir. Tablo 4.1'de yaklaşık 90 çerçevelik eğilme eylemine ait 20 eklem x, y, z koordinat bilgileri sıralı

bir şekilde görülmektedir. Her bir video süresi eylem özelliğine bağlı olarak yaklaşık 3-5 saniye, 320×240 çözünürlükte ve saniyede 30 çerçeve biçimindedir.



Şekil 4.19. Veri seti eylem yönleri




Şekil 4.20. Kinect® iskelet yapısı ve eklem numaraları

Tablo 4.1. Eğilme eylemine ait bazı çerçevelerdeki 20 eklem koordinatları


Ç. No.	X ₁	Y ₁	Z ₁	X ₂	Y ₂	...	Y ₂₀	Z ₂₀
1	1,08663	0,21933	3,17695	1,09811	0,30301	...	-	3,08180
2	1,08247	0,21500	3,15437	1,09400	0,29709	...	-	3,04491
3	1,08444	0,21417	3,15024	1,09566	0,29630	...	-	3,04405
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
42	0,11889	0,15968	2,63883	0,12095	0,22180	...	-	2,56746
43	0,10085	0,07515	2,66187	0,10314	0,12304	...	-	2,56611
44	0,08969	0,00606	2,68072	0,09114	0,03333	...	-	2,56669
45	0,09202	-0,01841	2,67424	0,09074	0,03654	...	-	2,57126
46	0,06512	-0,12952	2,64102	0,07026	-0,07251	...	-	2,49141
47	0,07073	-0,17126	2,62560	0,07217	-0,10917	...	-	2,42150
48	0,04098	-0,23513	2,51272	0,04542	-0,17313	...	-	2,43435
49	0,02836	-0,25028	2,49649	0,03953	-0,17948	...	-	2,43436
50	0,01971	-0,20450	2,48878	0,02509	-0,14303	...	-	2,43544
51	0,04640	-0,15322	2,59384	0,05072	-0,09524	...	-	2,42751
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
88	-0,96126	0,15732	2,14684	-0,96471	-0,96126	...	-	2,02487
89	-0,99254	-0,01720	2,17305	-0,97558	-0,99254	...	-	2,17642
90	-1,08473	-0,47624	2,21975	-1,06881	-1,08473	...	-	2,21735
91	-1,09156	-0,86594	2,24229	-1,07954	-1,09156	...	-	2,22446

Bu çalışmada elde edilen *yürüme, eğilme, oturma, çömelme, uzanma ve düşme* eylemlerine ait en genç denek (D1), orta yaşlı denek (D2) ve en yaşlı denek (D3) olmak üzere derinlik video çerçeveleri Şekil 4.21’de görülmektedir.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 4.21. FUKinect-Fall veri setindeki bazı deneklere ait 6 eylemin derinlik görüntüleri; (a) yürüme, (b) eğilme, (c) oturma, (d) çömelme, (e) düşme, (f) uzanma

5. DERİNLİK VİDEOLARINDA ETKİLİ DÜŞME TESPİTİ İÇİN FISHER VEKTÖR İLE ŞEKİL ÖZELLİKLERİNİN KODLANMASI


5.1. Giriş

Bu bölümde derinlik videolarındaki günlük eylemlerin düşmelerden ayırt edilmesi için derinlik tabanlı düşme tespiti başarımını geliştirmek için yeni bir yaklaşım önerilmiştir. Önerilen yaklaşımda özellikle düşme tespit performansını artırmak için EÖÜ özniteliklerinin, FV ile kodlanması temeline dayanmaktadır. Bu yaklaşımda, SDU Fall veri setindeki derinlik videolarının EÖÜ özniteliklerinin FV ile kodlanmasında elde edilen öznitelik vektörleri DVM sınıflandırıcı kullanılarak düşme tespiti ile günlük eylemler sınıflandırılmıştır.

5.2. Önerilen FV Kodlama Yöntemi

Önerilen yöntemin şematik gösterimi Şekil 5.1’de görülmekte olup bu çalışma üç temel bölümden oluşmaktadır. İlk bölümde derinlik videolarındaki her bir çerçeveye için EÖÜ özniteliklerinin çıkarımı yapılmıştır. İkinci bölümde, EÖÜ özniteliklerinin FV ile kodlanmasını içermektedir. FV kodlama bloğunda ilk olarak GKM tabanlı kod kütüphanesi oluşturulur. Sonra ilgili FV, GKM parametrelerine dayalı olarak hesaplanır. DVM sınıflandırıcı ise çalışmanın üçüncü aşamasını oluşturmaktadır. Bu aşamalara ait ayrıntılar aşağıda sunulmuştur.


Adım 1: Çalışmada [114]’deki EÖÜ özellikleri kullanılmıştır. Bu nedenle EÖÜ özelliklerinin oluşturulması kısaca açıklanacaktır. Ön plandaki insan vücudu, Gauss yönteminin adaptif karışım ile elde edilen derinlik video çerçeveleri arka plan bölümlerinden ayrılmıştır. Daha sonra insan silüetleri yaygın olarak tercih edilen Canny kenar dedektörü kullanılarak çıkarılmıştır [121]. Silüetlerin elde edilmesinden sonra şekil özniteliklerinin için EÖÜ kullanılmıştır. Çünkü EÖÜ öznitelik vektörü olarak kullanılan tüm maksimum noktaların (u, σ) koordinatları Bölüm 3.1’de açıklandığı gibi 2B öznitelik vektörünü oluşturmaktadır. Buradaki u normalize edilmiş uzunluğu göstermektedir. Deneysel çalışmalarda σ değeri 1-10 aralığında seçilmiş ve Şekil 5.2’de görüldüğü gibi σ değeri arttıkça silüetler küçülmekte ve sonunda silüetler daire benzeri şekiller haline dönüşmektedir.



Şekil 5.1. FV kodlama ile düşme tespit yöntemi blok diyagramı

Adım 2: Bu aşamada her bir çerçeveden çıkarılmış EÖÜ öznelikleri kodlanması için küçük kod kitapları ile düşük hesaplama maliyetine sahip ve basit doğrusal sınıflandırıcılarla dahi iyi performans gösterebilen FV kullanılmıştır. FV etkin bir şekilde her bir EÖÜ öznelikleri içine yüksek boyutlu gösterim ile kodlanmakta ve sonra bu kodlar global toplam havuzu ile bir tek vektör içerisinde toplanmaktadır. Kodlama ile birlikte FV'nin boyutu 2Kb olarak hesaplanmaktadır. Burada K , GKM'deki Gaussian bileşen sayısıdır ve b ise kodlanmış EÖÜ özellik vektörünün boyutudur. Çalışmalarımızda GKM kod kitabında ($K=256$) kullanılarak $b=2$ için EÖÜ öznelikleri FV kodlamasının boyutu 1024'tür.

Aynı kelime boyutu kullanılması durumunda KÇ'sında sadece 256 boyut elde edilmekte ve [122]'deki çalışmada gösterildiği gibi daha az ayırt edicidir. Ayrıca GKM'deki 1024 boyut verebilmesi için $1024/256=4$ kat daha fazla kod kitabına ihtiyaç duyulmaktadır [123, 124]. Bu durum kodlama için büyük bir hesap karmaşasına neden olmaktadır. Ayrıca FV birim varyans ve sıfır ortalama ile daha iyi normalize edilmektedir.




Şekil 5.2. EÖU öznitelikleri çıkarımının gösterimi [74, 114]

Adım 3: Bu aşamada kodlanmış özniteliklerin sınıflandırılma işlemi gerçekleştirilmektedir. Bölüm 3’te belirtildiği gibi son zamanlarda çok yaygın olarak kullanılan DVM sınıflandırıcı tercih edilmiştir.

5.3. DeneySEL Çalışmalar

DeneySEL çalışmalarda, Bölüm 4’te özellikleri detaylandırılan Şekil 5.3’te SDUFall veri setindeki Kinect® derinlik kamerasının farklı yönlerdeki bakış açılarına ait düşme, yürüme, eğilme, çömelme, oturma ve uzanma eylemlerinin içeren veri seti derinlik videoları EÖU öznitelikleri kullanılmıştır. Tüm deneyler, Intel (R) Core i7 MİB ve 32 GB RAM özelliklerine sahip bilgisayar, Matlab yazılımı ve FV kodlama için VIfeat araç kutusu kullanılmıştır [125].



Şekil 5.3. SDUFall veri setindeki 6 eyleme ait bazı görüntüler [114]

Deneysel çalışmalarda iki ayrı uygulama gerçekleştirilmiştir. İlk uygulamada düşme ve düşmenin olmadığı eylemlerin sınıflandırması, ikinci uygulamada ise 6 eylemin (yürüme, eğilme, oturma, çömelme, uzanma ve düşme) sınıflandırılması gerçekleştirilmiştir. Birinci ve ikinci uygulamalar için DVM sınıflandırıcı ve FV kernel ile birlikte kullanılmıştır. FV kernel sigma değerleri birinci uygulama için 18, 7 ve ikinci uygulama için 30 değerlerine ayarlanmıştır. Deneyler 10 katlı çapraz doğrulama ile 100 kez çalıştırılmıştır. Veri kümesinin yarısı (600 eylem) 256 boyutlu GKM kod kitabını oluşturmak için kullanılmıştır. Veri kümesinin kalan yarısı eğitim (300 eylem) ve test için kullanılmıştır. Çalışmalarda kod kitabının farklı boyutları için uygulamalar yapılmış ve en iyi başarımlar $K=256$ değeri için elde edilmiştir. İlk uygulamada; eğilme, yatma, oturma, çömelme ve yürüme eylemleri düşmenin olmadığı kategori olarak gruplandırılmıştır. Önerilen FV kodlama ile düşme tespit yöntemi, aynı veri setini kullanan KÇ-Değişken uzunlukta Parçacık Sürü Optimizasyonu (KÇ-DPSO), Sürü Optimizasyonu-Aşırı Öğrenme Makinası (SO-AÖM) ve KÇ-AÖM yöntemleri ile karşılaştırılarak sonuçlar Tablo 5.1’de verilmiştir.

Tablo 5.1. Düşme ve düşmenin olmadığı eylem sınıflandırma sonuçları

	Yöntemler				
	KÇ-DVM [74]	KÇ-AÖM [74]	KÇ-PSO-AÖM [74]	KÇ-DPSO-AÖM [74]	Önerilen Yöntem
Ortalama	% 63,12	% 84,36	% 85,34	% 86,83	% 88,83
Doğruluk					

Sonuçlar değerlendirildiğinde, FV-DVM yönteminin %88,83 ile en yüksek doğruluk derecesine sahip olduğu görülmektedir. Önerilen yöntem, KÇ-DPSO, (SO-AÖM) ve KÇ-AÖM yöntemlerinden sırasıyla yaklaşık %2, %3 ve %5’ten daha fazla doğruluk derecesine sahiptir. Tablo 5.1’deki diğer önemli bir gözlem ise FV kodlama yöntemi aynı sınıflandırıcıyı kullanan KÇ yöntemine göre %25 daha iyileştirilmiş bir performans ortaya koymuş olmasıdır.

Yapılan uygulamalarda aynı zamanda AÖM ile DVM, sınıflandırıcılar da karşılaştırılmıştır. AÖM için giriş ağırlıkları ve biasları rastgele [-1, +1] aralığında başlatılarak gizli nöronların sayısı 1000 ve aktivasyon fonksiyonu sigmoid olarak seçilmiş Tablo 5.2’de FV-AÖM’nin FV-DVM’den %1 daha iyi performansa sahip olduğu

görülmektedir. Ayrıca FV-AÖM hesaplama karmaşıklığının FV-DVM'den daha az olduğu da göz ardı edilmemelidir. Ayrıca önerilen yöntemin performans değerlendirmesini yapabilmek için k-EYK ve YSA sınıflandırıcılar ile de deneysel çalışmalar yapılmıştır. Her sınıflandırıcı için en iyi doğruluğun elde edildiği deneysel sonuçlar ve parametreleri kaydedilmiştir. K=5 (komşu sayısı) için k-EYK sınıflandırıcıdan en iyi sonuç elde edilmiştir [36]. YSA'da ise gizli katmandaki nöron sayısı 100 olarak seçilmiştir ve ölçekli eşlenik gradyan geri yayılım öğrenme algoritması seçilmiştir [37]. Elde edilen sonuçlar Tablo 5.2'de görülmektedir ve bu sonuçlara göre düşme ve düşme olmayan eylemlerin sınıflandırılmasında Yapay Sinir Ağı (YSA), k-EYK'dan yaklaşık %2 daha iyi başarıma sahip olduğu görülmektedir. Ayrıca Tablo 5.2'deki sonuçlar karşılaştırıldığında YSA ve k-EYK sınıflandırıcıların her ikisinin de DVM ve AÖM sınıflandırıcılardan başarımları olarak geride kaldıkları görülmektedir.

Tablo 5.2. Düşme tespitinde sınıflandırıcıların karşılaştırılması

	Yöntem-Sınıflandırıcılar			
	FV-AÖM	FV-DVM	FV-k-EYK	FV-YSA
Ortalama Doğruluk	%89,84	%88,83	%86,33	%88,01

KÇ-DVM, KÇ-AÖM, KÇ-DPSO-AÖM ve FV-DVM yöntemlerine ait ikinci tip uygulama sonuçları sırasıyla Tablo 5.3, 5.4 ve 5.5'te verilmiştir. Tablo 5.3'te görüldüğü üzere KÇ-DVM'nin diğer eylemleri de düşme olarak hatalı sınıflandırma olasılığı önemli derecede yüksek olduğu görülmektedir. Özellikle eğilme ve uzanma eylemlerini düşme olarak hatalı sınıflandırma oranları sırasıyla %80,08 ve %72,68'dir. En düşük başarımları %11,80 ile eğilme eyleminde elde edilmiş ve en iyi başarımları da %87,56 ile KÇ-DVM yönteminde düşme eyleminden elde edilmiştir.

Tablo 5.3. KÇ-DVM yöntemi için karışıklık matrisi (%)

	Tahmin					
	Düşme	Eğilme	Uzanma	Oturma	Çömelme	Yürüme
Düşme	87,56	1,03	5,01	0,81	1,69	3,89
Eğilme	80,08	11,80	2,47	0,65	0,80	4,27
Uzanma	72,68	1,72	20,86	2,00	1,13	0,61
Oturma	58,13	2,43	1,77	24,84	6,60	6,22
Çömelme	55,83	4,05	1,93	6,87	18,93	12,39
Yürüme	63,44	4,00	0,07	1,68	1,41	29,41

Tablo 5.4'teki sonuçlardan KÇ-AÖM'nin hatalı sınıflandırma oranlarının KÇ-DVM'den daha düşük olduğu görülmektedir. En yüksek doğru sınıflandırma oranı %70,07 ile düşme eyleminde ve en düşük sınıflandırma oranı %36,07 ile çömelme eyleminde kaydedilmiştir.

Tablo 5.4. KÇ-AÖM yöntemi için karışıklık matrisi (%)

	Tahmin					
	Düşme	Eğilme	Uzanma	Oturma	Çömelme	Yürüme
Düşme	70,07	1,95	14,79	4,04	3,99	5,16
Eğilme	6,50	41,69	12,58	9,36	11,34	18,52
Uzanma	15,74	5,01	56,69	8,80	8,35	5,41
Oturma	5,99	7,33	9,55	40,78	18,03	18,3
Çömelme	7,36	7,44	6,56	19,19	36,07	23,37
Yürüme	5,98	7,76	3,52	10,47	9,68	62,61

Düşme için en çelişkili eylem ise uzanmadır. Çünkü yaklaşık %15’lik düşme eylemini, uzanma eylemi olarak hatalı sınıflandırılmıştır.

KÇ-DPSO-AÖM yönteminin, KÇ-AÖM yönteminden daha iyi sınıflandırma başarımları sağladığı Tablo 5.5’te görülmektedir. Burada tüm eylemler için sınıflandırma doğrulukları verilmiştir. En düşük sınıflandırma doğruluğu çömelme eyleminde elde edilmiş ve en yüksek sınıflandırma doğruluğu ise düşme eyleminde kaydedilmiştir. Oturma ve çömelme eylemleri KÇ-DPSO-AÖM yönteminde en çok karıştırılan eylemlerdir. Çömelme eylemi %18,99 oranında oturma eylemi olarak ve %19,34 oranında oturma eylemi de çömelme eylemi olarak hatalı sınıflandırılmıştır.

Tablo 5.5. KÇ-DPSO-AÖM yöntemi için karışıklık matrisi (%)

	Tahmin					
	Düşme	Eğilme	Uzanma	Oturma	Çömelme	Yürüme
Düşme	70,64	1,98	13,78	4,27	4,03	5,30
Eğilme	5,36	50,03	12,54	7,28	11,72	13,07
Uzanma	12,85	6,75	60,47	7,73	7,72	4,45
Oturma	4,00	7,68	9,96	40,90	19,34	18,12
Çömelme	6,16	8,25	6,20	18,99	38,10	22,31
Yürüme	5,24	7,67	3,52	9,49	9,22	64,87

Son olarak Tablo 5.6’da, önerilen yöntemin başarımları oranları görülmektedir. Uzanma eylemi dışındaki tüm eylemlerde KÇ tabanlı yöntemlerden daha yüksek doğrulukta sınıflandırma yaptığı görülmüştür. Eğilme eyleminde en yüksek doğrulukta sınıflandırma elde edilirken, en hatalı sınıflandırma ise uzanma eyleminde görülmüştür. Uzanma eylemi %70 oranında, düşme eylemi olarak sınıflandırılmış ve %26 oranında çömelme eylemini de oturma eylemi olarak hatalı sınıflandırılmıştır.

Yapılan deneysel çalışmalarda görüldüğü gibi genel olarak FV-DVM diğer yöntemlere kıyasla daha az sınıflandırma hatalarına sahiptir. Tüm yöntemlerde, düşme eylemi ile en çok karıştırılan eylem çoğunlukla uzanma eylemidir. Bu takiben oturma ve çömelme en çok karıştırılan eylemlerdir. Bunun temel sebebi, bu eylemlerin birbirlerine

daha çok benzerlik göstermesidir. Düşme eylem silüetleri, uzanma eylem silüetlerine çok benzer özellikte olmasından kaynaklanmaktadır.

Tablo 5.6. FV-DVM yöntemi için karışıklık matrisi (%)

	Tahmin					
	Düşme	Eğilme	Uzanma	Oturma	Çömelme	Yürüme
Düşme	76	0	4	6	0	14
Eğilme	8	80	2	4	2	4
Uzanma	70	4	18	0	0	8
Oturma	0	6	0	78	4	12
Çömelme	2	0	0	22	64	12
Yürüme	24	0	2	2	0	72

Ayrıca Tablo 5.7’de 6 eylemin sınıflandırma genel başarımlarında görüleceği üzere FV-DVM en iyi başarıma sahiptir. Önerilen yöntemin, KÇ-DPSO-AÖM yönteminden %10 daha iyi bir başarıma sahip olduğu görülmektedir.

Tablo 5.7. 6 sınıf eylemin sınıflandırmasındaki başarımlar

	Yöntem			
	KÇ-DVM	KÇ-AÖM	KÇ-DPSO-AÖM	FV-DVM
	[74]	[74]	[74]	
Doğruluk	% 32,23	% 51,32	% 54,17	% 64,67

Bu deneysel çalışmalar dışında, önerilen yöntemin başarımlarını daha etkin değerlendirebilmesi amacıyla 24 ayrı gerçekçi senaryo içeren MultiCam veri seti kullanılmıştır [38]. Veri setinin ilk 22 senaryosu düşme eylemlerini, geriye kalan iki senaryosu ise oturma, uzanma ve çömelme gibi düşmenin olmadığı eylemleri içermektedir. Bu veri seti ile yapılan deneysel çalışmalardan elde edilen sonuçlar Tablo 5.8’de görülmektedir. Tablo 5.8’deki sonuçlara göre, her iki yöntemin de MultiCam veri seti ile yapılan deneysel çalışmaları benzer sonuçları olmakla birlikte önerdiğimiz yöntemin KÇ-

DPSO-AÖM, [126]'deki 3 kameralı yöntemlerden daha iyi başarıma sahip olduğu fakat 4 kameralı yöntemden daha düşük bir hassasiyet ve özgüllüğe sahip olduğu da tespit edilmiştir.

Tablo 5.8. MultiCam veri seti ile düşme ve düşme olmayan eylemlerin sınıflandırılması

Yöntem	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)
FV-DVM	97,92	92,31	98,32
KÇ-DPSO-AÖM [74]	97,20	99,93	91,97
3 Kamera [126]	-	80,60	100,00
4 Kamera [126]	-	99,70	99,80


6. SİLÜET YÖNELİM HACMİ İLE DERİNLİK VİDEOLARINDA ETKİN DÜŞME TESPİTİ

6.1. Giriş

Bu bölümde, SYH tanımlayıcılarına dayalı düşme tespiti için yeni bir yöntem önerilmiştir. SYR'lerin bir koleksiyonu olan SYH, sabit uzunluktaki silüet çerçevelerindeki eylem videolarının bir bölümünü temsil eden özelliklerden faydalanılarak SYH öznitelikleri elde edilmiştir. Daha sonra bir KÇ modeli ile her bir çerçevedeki eylemi tanımlayan SYH öznitelikleri ile KÇ-SYH oluşturulmuş olup eğitim aşamasında k-medoid kümeleme ile kod çizelgesi oluşturulmuştur. Naïve Bayes sınıflandırıcı eylem türünü belirlemesi için eğitilmiştir. Önerilen yöntemin değerlendirilmesi SDU-Fall ve Weizmann veri setleri ile gerçekleştirilmiştir. Deneysel çalışmalardan elde edilen sonuçlar, aynı veri setlerini kullanan diğer yöntemler ile karşılaştırılmıştır.

6.2. Önerilen SYH Yöntemi

Önerilen yöntemin genel yapısı Şekil 6.1'de görüldüğü üzere dört ana aşamadan oluşmaktadır. İlk olarak kaydedilen derinlik videolarının her bir çerçevesi bölütleme, gürültü giderme ve kenar tespiti gibi rutin ön işlemlerden geçirilmiştir.




Şekil 6.1. SYH ile düşme tespiti ve aşamaları

İnsan şekillerinin bölütlemesi, statik arka planın çıkarımından elde edilmiştir. Daha sonra morfolojik işlemler ile gürültüler giderilmiş ve silüetler kenar tespit ile Şekil 6.2’de görüldüğü gibi kapalı eğrilere dönüştürülmüştür.



Şekil 6.2. Her bir eyleme ait silüetin kapalı bir eğriye dönüşümü

İkinci aşamada SYH öznitelikleri çıkarılmaktadır. SYH’ler derinlik videolarındaki komşu çerçevelerden elde edilen basit SYR’lerdir. Başka bir ifade ile bir SYH, bir SYR dizisidir. Şekil 6.3’de kısa bir eylem dizisi ve bu diziyeye karşılık gelen SYR resimleri görülmektedir.



Şekil 6.3. İşlenmiş video çerçeveleri, ilgili SYR görüntüleri ve her bir silüetin 4 MÖU seviyelerin elde edilmesi

Ölçek uzay değişimlerinde eylemlerin birbirine karıştırılmasını engellemek amacıyla eğri eşleştirmeleri yapılmaktadır. Bu amaçla, özniteliklerin oluşturulmasında SYH’ler eşleştirilmiştir. SYH eşleştirme, SYR ile benzerdir. İki SYH arasındaki uzaklığı hesaplamak için sadece ilk çerçevedeki ilk morfolojik seviyeler eşleştirilir. Eşleştirme ile tanımlanan başlangıç noktasını bulmak için SYR’lerden biri döndürülür. İki SYH arasında aranan minimum uzaklık denklem 6.1 ile bulunabilir [77].

$$\left[D_{a,b}^{\min} \right] = \arg \min_{\alpha, r} (D_{a,b}(\alpha, r)) \quad (6.1)$$

Başlangıç noktası genellikle eğrinin başlangıçta örneklenen noktası olup genellikle elde edilen SYR'nin en sağındaki piksele karşılık gelmektedir. SYR'deki iki eğrinin a ve b noktaları arasındaki minimum uzaklığı bulmak için minimumlardan biri seçilerek farklı başlangıç noktaları ve renk kaymaları için tüm uzaklıklar hesaplanır. SYH'nin ilk SYR arasında başlangıç noktası farkı, her silüet için tüm MÖU düzeylerini de içeren SYH'lerin tüm SYR'leri için bu başlangıç noktasına kayması sağlanır.

Minimizasyon (başlangıç noktası arama) sadece ilk SYR için yapılır. Çünkü sadece bitişik çerçeveler olarak yakalanan bir SYR dizisinin SYH olduğu kabul edilmiştir. Böylece iki SYH arasındaki toplam uzaklık iki SYH'deki tüm SYR'lerin toplamı olarak denklem 6.2 ile hesaplanabilir;

$$D_{a,b}^{SYH} = \sum_{f=1}^{10} \sum_{m=0}^3 D_{a_f^m, b_f^m} \quad (6.2)$$

Denklem 6.2'deki $D_{a,b}^{SYH}$, tümü 4 MÖU düzeylerini içeren 10 bitişik silüet çerçevelerinin toplam SYR uzaklıkları olarak (toplamda $4 \times 10 = 40$ SYR çifti) SYH uzaklığını vermektedir [77]. Sürekli başlangıç noktasının aranması nedeni ile iki SYH arasındaki uzaklık üçgen eşitsizliğini sağlamamasından kaynaklanmaktadır. Bu aynı zamanda belirtilen uzaklığın sadece karşılıklı şekilde tanımlanan uzaklık olması nedeni ile ortak bir orijin için SYH'lerin uzaklıklarını tanımlamak mümkün değildir. Aslında bu gerçeğin temel sebebi ayırt edici karmaşık silüetlerin, karmaşık uzaklık ölçüm kabiliyeti SYH'lerin elde edilmesini sağlayan temel gerektir.

Her video klibi için SYH özellikleri çıkarıldıktan sonra, yöntemin üçüncü aşamasında KÇ-SYH modeli kullanılmıştır. Yukarıda bahsedildiği gibi iki SYH arasındaki uzaklığın sadece karşılıklı şekilde tanımlanması nedeni ile eğitim verileri için k-ortalamlar kümelemeyi uygulamak mümkün değildir. Bu sebeple, kod çizelgesi oluşturmak için k-ortalama algoritması yerine k-medoid kümeleme algoritması kullanılmıştır [118]. Bu kümeleme algoritması, bir kümenin merkezi olarak belirlenen bir nokta ve kümede etiketli noktalar arasındaki uzaklığı minimize etmek için kullanılır. K-ortalamlar algoritmasının aksine, k-medoid merkez olarak veri noktalarını seçer. K-medoid kümelemeden sonra, her

küme kod çizelgesinin bir video klibinden alınan özelliklerin haritalanmasından sonra bir kod kelimesi küme merkezi olmaya başlar. Bir video eylemi KÇ-SYH ile temsil edilen kelimelerin sayılmasından oluşan bir histograma sahiptir.

Son aşama da ise sınıflandırma yapmaktadır. Her eylem için elde edilen KSHY öznitelikleri eylem sınıflandırılması için Naïve Bayes sınıflandırıcıya uygulanmıştır.


6.3. Deneysel Çalışmalar

Önerilen yönteme ait tüm uygulamalar MATLAB ile gerçekleştirilmiştir. Deneysel çalışmalarda SDU-Fall [114] ve Weizmann [124] veri setleri kullanılarak iki ayrı uygulama gerçekleştirilmiştir.

İlk uygulama, Bölüm 4'te içeriği detaylandırılmış SDU-Fall veri seti ile yapılmıştır. SDU-Fall veri setinde SYH oluşturmak için çerçeve blok sayısı (N) 10 olarak seçilmiştir. Böylece 100 çerçeveli video klibinden 10 SYH çıkartılmıştır. Toplam SDU-Fall veri setindeki tüm video klipleri dikkate alındığında 18.119 SYH çıkartılmıştır. Eğitim için SYH'lerin %70 rastgele seçilmiş ve kalanlarda test için kullanılmıştır. KÇ-SYH kod çizelgesinin oluşturulmasında SYH'ler için k-medoid kümeleme kullanılmıştır [128]. KÇ-SYH'nin modelin oluşturulmasında kümeleme sayısının ne kadar önemli olduğu Şekil 6.4 ve 6.6'da görülmektedir.

İkinci uygulama ise yürüme, koşma, atlama, yana doğru koşma, eğilme, elleri sallama ve sıçrama gibi 9 ayrı eylemi içeren Weizmann veri seti ile gerçekleştirilmiştir [124, 125]. SYH oluşturmak için çerçeve blok sayısı (N) eylem video çerçeve uzunlukları dikkate alınarak 7 seçilmiştir. Eğitim için bazı eylemlerde SYH'lerin %66,6'sı bazı eylemlerde ise %55,5'i rastgele seçilmiş ve kalanlarda test için kullanılmıştır. Ayrıca buna bağlı olarak k-medoid sayıları 200 ve 250 olarak seçilmiştir.

Kod çizelgesi oluşturmadan sonra, her eyleme ait histogram oluşturulmuştur. Histogramların normalizasyonundan sonra, histogramların Olasılık Dağılım Fonksiyonu (ODF) elde edilmiştir. Bu ODF'ler nihai sınıflandırma için Naïve Bayes sınıflandırıcı da kullanılmıştır.



Şekil 6.4. 6 sınıf eylemin tanınmasında k-medoid kümeleme hassasiyeti

Önerilen yöntem, ilk olarak SDU-Fall [114] veri setindeki 6 eylemin tanınması için uygulanmıştır. Şekil 6.2 görüldüğü gibi en iyi başarıım k-medoid kümeleme sayısı $K=2000$ olarak seçildiğinde eylemlerin ortalama tanınma oranı %89,63 olarak elde edilmiştir. Ayrıca her bir eylemin doğru tanınma oranları Tablo 6.1’de görülmektedir.

Tablo 6.1. 6 eylemin tanınma başarıım oranlarının karşılaştırılması

Tahmin						
%89,63	 E	 D	 U	 O	 Ç	 Y
 E	%92,22	%1,11	%3,33	%0	%3,33	%0
 D	%0	%84,44	%15,56	%0	%0	%0
 U	%0	%2,22	%97,78	%0	%0	%0
 O	%0	%0	%1,11	%98,89	%0	%0
 Ç	%4,44	%0	%2,22	%0	%93,33	%0
 Y	%10	%0	%5,56	%11,11	%2,22	%71,11

Tablo 6.1’de görüldüğü gibi %98,89 ile en yüksek tanıma doğruluğu oturma eylemine sağlanmıştır. Öte yandan en düşük tanıma doğruluğu %71,11 ile yürüme eyleminde kaydedilmiştir. Yürüme bağımsız bir eylem olmasına rağmen, aynı zamanda diğer eylem kategorileri içerisinde var olan bir alt eylemdir. Çünkü her eylem için denekler eylem sahnesine yürüyerek girmekte ve yürüyerek ayrılmaktadırlar. Bu durum hemen hemen tüm eylem dizileri içerisinde 10 çerçeve yürüme dizisini içermekte ve buna bağlı olarak tüm eylem histogramlarında yürüme alt eylem karşılığı olan SYH medoidler içermesine neden olmaktadır. Ayrıca eylem süresince yürüme sahnelerinin çerçeveleri uzun olduğundan hatalı pozitiflerin oranını artışına neden olmaktadır. Ayrıca düşme eylemi %15,56 oranında çoğunlukla uzanma eylemi olarak hatalı şekilde sınıflandırılmaktadır. Bu durum her iki eylemin oldukça benzer olmasından kaynaklanmak birlikte her iki eyleminde çoğunlukla zeminde gerçekleşmesi nedeni ile derinlik bölütlemesindeki gürültülerinden kaynaklanmaktadır. Bu durum Şekil 6.5’teki SDU-Fall veri seti eylem örneklerinde görülebilmektedir. Ayrıca Şekil 6.5’te eylemlerin hatalı olarak sınıflandırılma durumları da yer almaktadır.

Başarım	Eylem Dizisi										Sınıf/ Karar	
											E	E
											D	D
											D	U
											U	U
											O	O
											Y	Y
											Y	Y
											Y	E

Şekil 6.5. SDU-Fall veri seti eylem örneklerindeki gürültü ve eylemlerin sınıflandırılması

Tablo 6.1’deki en iyi başarımla oturma eyleminde elde edilmiştir. Bu durum oturma eyleminin, diğer herhangi bir eylemin alt eylemi olmaması nedeni ile daha ayırt edici özelliğe sahip olmasıdır.

SDU-Fall veri seti ile yapılan ikinci uygulama ise düşme ve düşmenin olmadığı durumların sınıflandırılmasıdır. Bu nedenle kümeleme sayısına dayalı olarak deneysel çalışmalar tekrar edilmiştir. Şekil 6.6’daki sonuçlardan görüldüğü üzere küme sayısı yine $K=2000$ olduğunda %91,89 ile en yüksek başarımla elde edilmiştir. Küme sayısının azaltılması durumunda düşme ve düşmenin olmadığı eylemlerin tanınmasındaki performansı %78’lere kadar düşmektedir.



Şekil 6.6. Düşme ve düşme olmayan eylemlerin tanınmasında k-medoid kümeleme hassasiyeti

Ayrıca, düşme ve düşmenin olmadığı eylemlerin karşılaştırma oranları Tablo 6.2’de görülmektedir. Tablo 6.2’de görüldüğü gibi, düşme tespitinde %84,44 oranında başarıyı sağlamıştır. Fakat önerilen yöntem, düşmenin olmadığı eylemleri tanınmasında %99,33 gibi yüksek bir oranda başarı sağladığı görülmektedir.

Tablo 6.2. Düşme ve düşmenin olmadığı eylemlerin başarı oranlarının karşılaştırılması

	Tahmin	
	 D	 D
%91,89		
 D	%84,44	%15,56
 D	%0,67	%99,33

Önerilen yöntemin başarı değerlendirilmesinin daha etkili yapılabilmesi için SDU-Fall veri setini kullanılan diğer yöntemler ile karşılaştırması Tablo 6.3’te görülmektedir. Tablo 6.3’te görüleceği gibi SYH ile düşme tespit yöntemin eylem sınıflandırma başarımının önemli ölçüde arttırılmıştır.

Tablo 6.3. 6 sınıf eylemin sınıflandırmasındaki başarımın karşılaştırılması

	Yöntem		
	KÇ-DPSO-AÖM [74]	FV-DVM [21]	Önerilen Yöntem
Doğruluk	%54,17	%64,67	%89,63

Yöntem, FV-DVM yönteminden %25 ve KÇ-DPSO-AÖM yönteminden %35 daha yüksek başarım oranına sahiptir. Yapılan literatür incelemelerine göre bu başarım SDUFall veri seti için en yüksek başarım SYH ile düşme tespit yöntemi ile elde edilmiştir.

Ayrıca SYH tanımlayıcının, EÖU tanımlayıcılar ile karşılaştırıldığında tanıma yeteneğinin geliştirildiği Tablo 6.4'teki sonuçlarından görülebilmektedir. Basit bir öğrenme çerçevesi kullanarak önerilen yöntemin çoklu sınıf tanıma yeteneği, EÖU özellikleri ve daha karmaşık öğrenme stratejisi kullanan KÇ-DPSO-AÖM yönteminde daha yüksektir.

Tablo 6.4. SDUFall veri seti ile düşme ve düşme olmayan eylem sınıflandırmasında başarımın karşılaştırılması

	KÇ-DPSO-AÖM [74]	FV-DVM [21]	Önerilen Yöntem
Doğruluk	%86,83	%88,83	%91,89

Tablo 6.4'te görüldüğü gibi FV-DVM yönteminden %3 ve KÇ-DPSO-AÖM yönteminden %5 daha iyi bir başarıma sahip olduğu görülmektedir.

Weizmann veri seti ile yapılan farklı uygulamalar için farklı eğitim boyutları (5/9 veya 6/9) ve k-medoidler için farklı sayılarda kümeler (200-250) ile %100 gibi bir mükemmel başarım elde edilmiştir. Tablo 6.5'te aynı veri setini kullanan Uzay-Zaman Şekilleri (UZŞ), Ardışıl Kovaryans matris En Yakın Komşu (AK-EYK) yöntemler ile karşılaştırmalar görülmektedir.

Tablo 6.5. Weizmann veri setini kullanan yöntemlerin başarım karşılaştırılması

	UZŞ [129]	AK-EYK [130]	Önerilen Yöntem
Doğruluk	%97,83	%100	%100

Bu veri seti, SDU-Fall veri seti eylem içerikleri bakımından kıyaslandığında eylem kümesi yoğunluğunun yanı sıra karmaşıklığı daha azdır. Fakat buna rağmen bu veri kümesinde %100 başarımla elde edebilen çok az sayıda yöntem bulunmaktadır. Ancak SYH gibi basit ve etkili tanımlayıcılar kullanarak bu sonuçlar elde edilebilmiştir. Ayrıca bu başarımda eğitim verilerindeki küme sayısı da önemli katkı sağlamıştır.




7. EKLEM TABANLI ETKİLİ DÜŞME TESPİTİ

7.1. Giriş

Bu bölümde, düşme tespiti için 3B iskelet verisinin 2B indirgenmesine dayalı yeni bir yöntem önerilmiştir. Yöntemde, 3B iskelet verileri 2B xy ve zy koordinat eksenlerine kalça merkezi eklemi referans alınarak tüm eklemleri kapsayacak şekilde iç içe geçmiş iki daireye yerleştirilmiştir. Bu daireler belirli açılar ile dilimlenerek bölgelere ayrılmış ve kodlanmıştır. Öznitelikler her bir eklem için bütün çerçevelerdeki bölgelerin ortalamaları alınarak elde edilmiştir [24]. Öznitelikler DVM ve k-EYK sınıflandırma yöntemleri kullanılarak düşme ve günlük eylemler tespit edilerek sınıflandırılmışlardır.


7.2. Önerilen Eklem Tabanlı Düşme Tespit Yöntemi

Kinect® derinlik görüntülerini işleyerek eklem pozisyonları tanımlamaktadır. İlk önce derinlik görüntülerindeki bir piksel için belirlenen eklem pozisyonunu tahmin etmekte ve her piksel için doğruluk düzeyini hesaplamaktadır. Bundan sonra doğruluk düzeyleri ile verilen iskelet etiketlerinden iskeleti seçmektedir [131]. Kinect®'in insan iskeleti için kullandığı iskelet modeli Şekil 7.1'de gösterilmiştir.




Şekil 7.1. Kinect® iskelet eklem yapısı [131]

Vücudun K tane eklemle temsil edildiği T adet çerçeveden oluşan bir eylemde herhangi bir t_i çerçevedeki ve herhangi bir k eklemine x, y ve z koordinatları $x_K^{(t)}, y_K^{(t)}, z_K^{(t)}$ şeklindedir. Böylece 20 eklem üç eksene ait eklem vektörü; $E = [x_1^{(t)}, y_1^{(t)}, z_1^{(t)}, x_2^{(t)}, y_2^{(t)}, z_2^{(t)}, \dots, x_K^{(t)}, y_K^{(t)}, z_K^{(t)}]$ olarak yazılabilir.



Şekil 7.2. Eklem tabanlı düşme tespit yönteminin aşamaları

İskelet verileri ile düşme tespiti için önerilen yöntemin genel yapısı Şekil 7.2’de görülmektedir. İlk aşamada Kinect® derinlik kamerasından alınan 3B eklem koordinatlarını eylem tanıma için, iki adet (xy ve zy) 2B eklem koordinatlarına indirgeyerek Şekil 7.3’teki model oluşturulmuştur [24, 132, 133]. Böylece ölçekten bağımsız bir poz elde edilmiştir. Bu modelde, Shotton yöntemine göre kalça merkezi eklemi referans alınmıştır [134]. Referans eklem, xy ve zy koordinat sistemlerinin orijin noktasına gelecek şekilde konumlandırıldıktan sonra, iç içe çizilmiş iki daire ile tüm iskelet çevrelenmiştir. Daha sonra daireler belirli açılar (model 30° ’lik açı) ile bölgelere ayrılmıştır. Eksenler belirli θ açısı ile bölgelere ayrıldığında oluşacak bölge sayısı $n_b = 2 \times \left(\frac{360}{\theta} \right)$ bağıntısı ile hesaplanabilir.



Şekil 7.3. 2B eksen modeli ve bölgeleri

Bu aşamadan sonra her bir eklem, Denklem 7.1'deki bağıntıya göre referans ekleme göre düzenlenerek eklem vektörü yazılabilir;

$$E = [0, 0, 0, x_2 - x_1, y_2 - y_1, z_2 - z_1, \dots, x_K - x_1, y_K - y_1, z_K - z_1] \quad (7.1)$$

burada E eklem vektörünü tanımlamaktadır. Her bir eklemin, referans ekleme göre açısı (α_i) ve uzaklığı (d_i) Denklem 7.2 ve Denklem 7.3 ile hesaplanabilir.

$$\alpha_i = \arctan \frac{y_i - y_1}{x_i - x_1} \quad (7.2)$$


$$d_i = \sqrt{(x_i - x_1)^2 + (y_i - y_1)^2} \quad (7.3)$$

Ayrıca $R_{xy} = d_{\max}$ ve $r_{xy} = \frac{R_{xy}}{2} = \frac{d_{\max}}{2}$ bağıntıları ile dıştaki ve içteki çemberlerin yarıçapları hesaplanabilir. Böylece seçilen xy eksenine göre bir çerçevedeki eklem açıları $A_{xy} = [0, \alpha_2, \alpha_3, \alpha_4, \dots, \alpha_K]$ ve bütün eklemlerin referans ekleme olan uzaklıkları $D_{xy} = [0, d_2, d_3, d_4, \dots, d_K]$ açı ve uzaklık vektörleri yazılabilir. Aynı işlemler yz eksenini için de yapılarak A_{zy} ve D_{zy} vektörleri elde edilir.

Bir çerçevede eklemlerin referans ekleme olan uzaklığı ve açısına bağlı olarak hangi bölgede bulunduğu tespit edilir. Buna göre eklemlerin bulunduğu bölge vektörü de $B_{xy} = [0, b_2, b_3, b_4, \dots, b_K]$ şeklinde yazılabilir. Aynı işlemler zy ekseninde yapılarak B_{zy}

vektörü elde edilir. Böylece tüm çerçevelerdeki her bir eklem için B_{xy} ve B_{zy} özellikleri elde edilmiştir. Bu şekilde referans eklem dışındaki 19 eklem, her bir çerçevedeki konum bilgisi, hangi bölgede olduğu belirlenmiş olur. Bir hareket ya da eylem boyunca bir eklem, bütün çerçevelerdeki açı, referansa olan uzaklık ve bölge özelliklerinin ortalaması alınarak eylemin sınıflandırılabilmesini sağlayacak öznitelikler elde edilmiştir. Aynı zamanda bu *ortalama tanımlayıcı* olarak ifade edilebilmektedir.

Her iki eksen için de bu yöntem ile öznitelikler oluşturulduğunda eylemlere ait zamansal bilginin kaybolduğu görülmüştür. Bu durum birbirinin tersi olan eylemlerin karıştırılmasına sebep olmaktadır. Bu sorunun çözümü için zamansal hiyerarşik yapı kullanılmıştır [135]. Bir eylemdeki T adet çerçeve için zamansal hiyerarşik yapı Şekil 7.4'te görülmektedir. Önce çerçevelerin hepsi $t = 1$ 'den T 'ye (O_1) sonra sıralı olarak $t = 1$ 'den $\frac{T}{2}$ 'ye (O_2), $\frac{T}{4}$ 'ten $\frac{3T}{4}$ 'ye (O_3) ve son olarak $\frac{T}{2}$ 'den T 'ye (O_4) kadar olan çerçevelerin her eklem için ortalaması alınarak öznitelikler oluşturulmuştur. Böylece öznitelik sayısını 4 katına çıkarmıştır.





Şekil 7.4. Ortalama tanımlayıcının zamansal hiyerarşik yapısı [135]

7.3. DeneySEL Çalışmalar

Bu bölümde, önerilen yöntemin test edilmesi için bu tez çalışmasında kullanılmak üzere oluşturulan FUKinect-Fall ve mevcut UTKinect-Action [119] veri setleri kullanılmıştır. DeneySEL çalışmalarda elde edilen sonuçların değerlendirilmesi yapılmıştır.

Deneysel çalışmalarda kullanılan FUKinect-Fall veri setindeki *yürüme*, *eğilme*, *oturma*, *çömelme*, *uzanma* ve *düşme* eylemlerinden oluşmaktadır. Veri setinden seçilen bazı çerçevelerin iskelet gösterimi ve derinlik görüntüleri Şekil 7.5'te görülmektedir.





Şekil 7.5. FUKinect-Fall veri setindeki eylemlerin iskelet verilerine ait iskelet ve derinlik görüntüleri; (a) Yürüme, (b) Eğilme, (c) Oturma, (d) Çömelme, (e) Uzanma, (f) Düşme

FUKinect-Fall ile yapılan deneysel çalışmalarda Şekil 7.3'teki iskelet modeline göre 5° , 10° , 30° ve 45° 'lik açılar ile sırasıyla $2 \times (360^\circ / \text{açı}) = 144$, 72, 24 ve 16 bölgelere ayrılmıştır. Her bölge açısı için ayrı ayrı öznitelikleri oluşturulmuştur. Eylemlerin sınıflandırılması için $19 \text{ eklem} \times 4 \text{ zamansal yapı} \times 2 \text{ eksen}$ olmak üzere toplam 152 öznitelik

k-EYK ve DVM sınıflandırıcıların girdi katmanına uygulanmıştır. İlk olarak önerilen yöntem ile 6 eylem sınıflandırılmış ve bu 6 eylemin sınıflandırması için iki ayrı uygulama gerçekleştirilmiştir. Birinci uygulamada özniteliklerin %50'si eğitim, diğer %50'si de test için kullanılmış, ikinci uygulamada ise özniteliklerin %75'i eğitim ve %25'i test için kullanılmıştır. Yapılan deneysel çalışmalarda k-EYK ve DVM algoritmaları ile 6 eylemin sınıflandırılma sonuçları sırası ile Tablo 7.1 ve Tablo 7.2'de görülmektedir.

Tablo 7.1. k-EYK ile 6 eylemin sınıflandırılma sonuçları (%)

Bölge açısı	<i>k</i>	1. Uygulama	2. Uygulama
5°	1	88,13	88,75
	3	88,96	90,00
	5	87,29	91,25
	7	88,54	91,25
	9	87,08	90,83
	11	88,33	90,83
10°	1	88,13	88,33
	3	90,00	90,83
	5	90,63	91,67
	7	89,38	92,50
	9	88,33	92,08
	11	87,71	91,67
30°	1	82,29	84,17
	3	83,75	85,00
	5	85,83	87,08
	7	85,42	85,42
	9	83,96	85,42
	11	83,33	86,67
45°	1	85,21	86,67
	3	87,29	89,58
	5	87,08	88,75
	7	87,71	88,75
	9	87,08	89,17
	11	86,04	87,92

Tablo 7.1’de görüldüğü gibi her iki uygulamada da k-EYK için en iyi sınıflandırma 10°’lik bölge açısı ile elde edilmiştir. Eğitim ve test verilerinin eşit seçildiği birinci uygulamada k=5 için %90,63 iken, ikinci uygulamada k=7 için %92,50 doğrulukta eylem sınıflandırması yapılmıştır.

Tablo 7.2. DVM ile 6 eylemin sınıflandırılma sonuçları (%)

Bölge açısı	1. Uygulama	2. Uygulama
5°	84,79	88,75
10°	84,38	89,17
30°	82,79	87,92
45°	84,38	88,75

DVM ile yapılan sınıflandırma sonuçları incelendiğinde bölge açısının azalması ile hassasiyetin daha da arttığı ve ilk uygulama için %84,79 ve ikinci uygulama için %89,17 doğrulukta 6 eylemin sınıflandırılmasının gerçekleştirildiği görülmektedir.

Bu çalışmanın temel amacı, düşme ve düşmenin olmadığı durumların sınıflandırılmasıdır. Yine burada da 6 eylemin sınıflandırılmasında olduğu gibi iki ayrı uygulama gerçekleştirilmiştir. k-EYK ve DVM ile yapılan deneysel çalışma sonuçları sırası ile Tablo 7.3 ve Tablo 7.4’te verilmiştir.

Tablo 7.3. k-EYK ile düşme ve düşme olmayan eylemlerin sınıflandırılma sonuçları (%)

Bölge açısı	<i>k</i>	1. Uygulama	2.Uygulama
5°	1	94,38	94,17
	3	93,33	93,75
	5	92,50	91,67
	7	95,00	95,00
	9	93,13	93,75
	11	90,83	92,08
10°	1	93,54	93,33
	3	92,50	95,00
	5	91,88	95,00
	7	92,92	93,33
	9	92,50	95,83
	11	91,67	93,33
30°	1	93,13	92,08
	3	93,54	90,42
	5	91,67	90,00
	7	92,71	92,08
	9	91,67	92,08
	11	90,83	90,00
45°	1	92,71	96,25
	3	91,25	95,42
	5	90,83	95,00
	7	92,50	96,25
	9	90,00	94,58
	11	88,33	93,33

Düşme ve düşmenin olmadığı eylemlerin k-EYK ile sınıflandırma sonuçları incelendiğinde birinci uygulama için en iyi başarımın %95 ve ikinci uygulamada yapılan tüm deneysel çalışmalarda ise en iyi başarımın %96,25 olarak elde edildiği görülmektedir.

Tablo 7.4. DVM ile düşme ve düşme olmayan eylemlerin sınıflandırılma sonuçları (%)

Bölge açısı	1. Uygulama	2.Uygulama
5°	95,00	97,08
10°	94,37	97,08
30°	93,96	95,83
45°	93,96	97,08

DVM ile düşme ve düşmenin olmadığı (*yürüme, eğilme, oturma, çömelme ve uzanma*) eylemlerin sınıflandırılmasında birinci uygulamada 5°'lik bölge açısında %95 oranında, ikinci uygulamada ise 30°'lik bölge açısı dışındaki diğer bölge açılarında %97,08 doğrulukta düşme tespiti yapılabildiği görülmektedir.

Önerilen yöntemin başarımlarını değerlendirmesinin, daha etkin karşılaştırılabilmesi için deneysel çalışmalarda bu tez için özel olarak hazırlanan veri seti ile birlikte birçok araştırmacı tarafından yaygın olarak kullanılan UTKinect-Action veri seti ile de deneysel çalışmalar yapılmıştır. Bu veri setini kullanan Derinlik Uzay Zamansal İlgili Noktaları –Kubik Benzerlik Özelliği (DYUZİN-KBÖ), Rastgele orman ve Süper Normal Vektör (SNV) yöntemleri ile eklem tabanlı düşme tespit yönteminin veri setindeki 10 eylemin tanınmasındaki ortalama başarımların karşılaştırması Tablo 7.5'te görülmektedir.

Tablo 7.5. UTKinect-Action veri seti ile yapılan çalışmaların başarımlarını sonuçları

Yöntem	DYUZİN+ DKBÖ [136]	Rastgele Orman [137]	SNV [138]	Önerilen Yöntem
Doğruluk	%85,80	%87,90	%88,90	%90,03

Tablo 7.5'te görüldüğü gibi [136] ve [137]'teki çalışmalardan sırasıyla yaklaşık %4 ve %2 daha iyi başarımlar elde edildiği görülmektedir. Ayrıca UTKinect-Action veri setini kullanan diğer en iyi yöntemden yaklaşık %1'lik daha iyi başarımlar sağlandığı görülmektedir. Bu durum önerilen yöntemin iskelet eklem verileri kullanılarak eylem tanıma için de etkin bir şekilde kullanılabileceğini göstermektedir.

8. SONUÇLAR VE DEĞERLENDİRME

Bu tez çalışmasında, derinlik kamera görüntülerinden yaşlı düşmelerinin tespiti için üç farklı yöntem önerilmiştir. Önerilen ilk yöntemde, derinlik görüntülerine ait EÖÜ özniteliklerinin kodlanmasında KÇ yerine FV kodlama kullanılmıştır. Böylece kod çizelge sayısı artırılarak insan eylemlerinin tanınmasındaki ayırt edilebilirlik daha da geliştirilmiştir. Yöntemin etkinliği SDU-Fall veri seti üzerinde gerçekleştirilen uygulamalar ile gösterilmiştir. Önerilen diğer bir yöntem de ise derinlik görüntülerinden öznitelik çıkarımında literatürde yaygın olarak kullanılan EÖÜ yerine, SYH ile öznitelik çıkarımıdır. Bu şekilde derinlik görüntülerindeki silüetlerden elde edilen kapalı eğrilerde keskin köşe veya belirgin noktalara ihtiyaç duyulmadan da daha etkin şekilde öznitelik çıkarımı yapılmıştır. Bu yöntemin, etkinliği SDU-Fall ve Wiezmann veri setleri üzerinde gerçekleştirilen uygulamalar ile gösterilmiştir. Tez çalışması için önerilen son yöntemde ise 3B iskelet eklem verisi iki ayrı 2B eklem verisine indirgenerek öznitelik çıkarımını sağlayan bir algoritma önerilmiştir. Bu algoritmada, insan iskelet sistemindeki kalça merkezi eklemi referans alınarak bir eylem süresince her bir eklem referans eklem olan uzaklığı ve açısının hesaplanmasına dayalı öznitelik çıkarımı kullanılmıştır. Önerilen algoritmanın etkinliği bu tez çalışması için oluşturulan FUKinect-Fall ve UTKinect veri setleri üzerinde gerçekleştirilen deneyler ile gösterilmiştir. Deneysel çalışmalardan elde edilen sonuçların değerlendirmesi aşağıda her bir bölüm için ayrı ayrı yapılmıştır.

8.1. Sonuçların Değerlendirilmesi

Bölüm 4: Bu bölümde, tez çalışmalarında kullanılmak üzere 19-72 yaş aralığında, farklı fiziksel özelliklerdeki 21 erkek deneğin katılımı ile yürüme, eğilme, oturma, çömelme, uzanma gibi günlük eylemler ve düşme eylemini içeren FUKinect-Fall veri seti oluşturulmuştur. Her bir eylem Kinect'in farklı görüş açıları ile 8'er kez tekrar edilmiştir. 168 adeti düşme olmak üzere toplamda 1008 adet eylemin bulunduğu veri seti, mevcut veri setlerinden farklı olarak hem derinlik hem de iskelet veri ile deneysel çalışma imkanı sunmaktadır.

Bölüm 5: Bu bölümde geliştirilmiş derinlik tabanlı DTS başarımını arttırmak için literatürde bilgisayar görmesinde son dönemlerde yaygın olarak kullanılan KÇ kodlamanın

aksine FV kodlama önerilmiştir. FV kodlama, daha yüksek boyutlu kod çizelgesine sahip olması ve hesaplama yükünün düşük olması gibi özelliklerinden dolayı tercih edilmiştir. Ayrıca FV, lineer sınıflandırıcı olan DVM ile birlikte kullanıldığında dahi yüksek oranda başarımlar sağlamaktadır. KÇ kodlamaya benzer şekilde, FV kodlama da GKM algoritmasına dayalı kod çizelgesini oluşturmak için giriş EÖÜ özellikleri bir kısmını kullanmaktadır. Bu amaçla önerilen yöntemin etkinliğini göstermek için tek derinlik kamerası ile oluşturulan SDU-Fall veri seti ile çeşitli deneyler yapılmıştır. Önerilen yöntemin düşme tespitindeki başarımları %88,83'dir. Günlük eylemlerin sınıflandırılmasındaki başarımları %64,67'dir. Önerilen yöntem düşme tespitinde aynı veri setini kullanan diğer en iyi yöntemden yaklaşık %2 ve eylem sınıflandırma ise yaklaşık %10 daha yüksek başarımlara sahiptir.

Bölüm 6: Bu çalışmada, derinlik görüntülerinden öznitelik çıkarımı için SYH yöntemi önerilmiştir. Bu yöntemde, eylem videolarındaki silüet çerçevelerinden eylem videolarını temsil eden özelliklerden faydalanılarak SYH öznitelikleri elde edilmiştir. Daha sonra her bir çerçevedeki eylemi tanımlayan SYH öznitelikleri eğitim aşamasında k-medoid kümeleme ile KÇ-SYH öznitelikler kod çizelgesi oluşturulmuştur. Özniteliklerin sınıflandırılabilmesi için Naïve Bayes sınıflandırıcı kullanılmıştır. Önerilen yöntemin üstünlüğünü göstermek için SDU-Fall ve Weizmann veri setleri ile çeşitli deneyler yapılmıştır. Tek bir derinlik kamerası kullanılarak oluşturulan SDU-Fall veri seti ile yapılan kapsamlı deneylerde düşme tespitinde %91,89'luk başarımlar oranına ulaşılmıştır. Bu başarımlar oranı aynı veri setini kullanan KÇ-DPSO-AÖM yönteminden %5 ve FV-DVM yönteminden yaklaşık %3 daha yüksektir. Ayrıca 6 eylemin tanınmasında %89,63 oranında bir başarımlar elde edilmiştir. Bu tanıma oranı aynı zamanda KÇ-DPSO-AÖM yönteminden yaklaşık %35 ve FV-DVM yönteminden %25 daha yüksektir. Weizmann eylem veri seti ile farklı eğitim seti boyutları ve k-medoid kümelerin farklı sayılarıyla yapılan çeşitli deneylerde %100 oranında eylem tanıma performansına ulaşılmıştır. Bu sonuç yöntemin gerçek parametreler ile çok etkin ve literatürdeki en iyi eylem tanıma yöntemlerinden biri olduğunu göstermiştir.

Bölüm 7: Bu çalışmada, iskelet eklem verilerine dayalı yeni bir yöntemi önerilmiştir. Bu yöntemde, 3B iskelet eklem verileri iki ayrı 2B (xy, zy) eklem verisine indirgenmektedir. Kalça merkezi eklem noktası, 2B kartezyen koordinat sistemi merkezine konumlandırılarak referans alınmıştır. Bu koordinat sisteminde, tüm iskeleti kapsayacak şekilde iç içe geçmiş iki daireye yerleştirilmiştir. Bu daireler belirli açılar ile dilimlenerek bölgelere ayrıldıktan sonra bir eylem boyunca her bir eklem referans eklem olan uzaklığı, açısı ve eklem bulunduğu bölgeyi içeren öznitelikler elde edilmiştir. Özniteliklerin sınıflandırılabilmesi

için k-EYK ve DVM sınıflandırıcılar kullanılmıştır. Yöntemin etkinliğini göstermek için bu tez çalışmasında oluşturulan FUKinect-Fall ve UTKinect veri setleri ile çeşitli deneyler yapılmıştır. Önerilen yöntemin FUKinect-Fall ile yapılan deneysel çalışmalarında %97,08 doğrulukta düşme tespiti yapılmıştır. Sadece derinlik görüntüsü kullanılarak yapılan çalışmalardan yaklaşık %4 oranında daha yüksek başarımlar elde edilmiştir. Ayrıca yöntem başarımının daha iyi değerlendirilebilmesi için sadece iskelet verilerinin kullanıldığı UTKinect-Action veri seti ile de deneysel çalışmalar yapılmıştır. Aynı veri setini kullanan en iyi başarıma sahip çalışmadan yaklaşık %1 daha iyi başarımlar elde edilmesi yöntemin etkinliğini göstermektedir.

8.2. Öneriler

Tez süresince yapılan çalışmalar değerlendirildiğinde ileride yapılacak çalışmalar için önerilebilecek bazı konular şunlardır;

1. Düşme tespiti ve eylem tanıma yönelik yapılacak çalışmalar için mevcut veri setleri dışında oluşturulacak veri setlerinde düşme eylemleri, öne, arkaya, yana, sandalyede otururken, yatakta uyurken veya yürürken düşme gibi farklı senaryolar düşünülebilir.
2. Düşme tespitine yönelik oluşturulan veri setlerinde eylemlerin simüle edilmesinde yaşlı erkek ve kadın deneklerin yer alması sağlanabilir.
3. Daha etkin düşme tespiti için Kinect'in konuşma tanıma ve ses özelliklerinin kullanımını içeren algoritmaları ile derinlik tabanlı algoritmaların birlikte kullanımı araştırılabilir.
4. Gelecekte düşme tespitinde bölüm tabanlı şekil algılama yaklaşımının uygulanabilirliğini ve DTS'nin başarımının geliştirilmesi için derin öğrenme olarak adlandırabileceğimiz yeni sınıflandırıcılar incelenebilir.

KAYNAKLAR

- [1] **Kemp, F. M. and Acheson, R. M.** (1989). Care in the community–elderly people living alone at home. *Journal of Public Health*, 11(1), 21-26.
- [2] World Population Ageing 2013, in ST/ESA/SER.A/348. 2013, United Nations, Department of Economic and Social Affairs, Population Division
- [3] <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=15844> 30 Mayıs 2016
- [4] World Health Organization: Global report on falls prevention in older age. [http://www.who.int/ageing/publications/Falls_prevention7March.pdf] 30 Mayıs 2016
- [5] **Fletcher, P. C. and Hirdes, J. P.** (2002). Risk factors for falling among community-based seniors using home care services. The Journals of Gerontology Series A: Biological Sciences and Medical Sciences, 57(8), M504-M510.
- [6] **Tinetti, M. E., Speechley, M. and Ginter, S. F.** (1988). Risk factors for falls among elderly persons living in the community. *New England journal of medicine*, 319(26), 1701-1707.
- [7] **Jensen, J., Lundin-Olsson, L., Nyberg, L. and Gustafson, Y.** (2002). Falls among frail older people in residential care. *Scandinavian Journal of Public Health*, 30(1), 54-61
- [8] **Vellas, B. J., Wayne, S. J., Romero, L. J., Baumgartner, R. N. and Garry, P. J.** (1997). Fear of falling and restriction of mobility in elderly fallers. *Age and ageing*, 26(3), 189-193
- [9] **Rhuma A.** 2014. Intelligent computer vision processing techniques for fall detection in enclosed environments, Leicestershire UK, PhD Theses, Loughborough University <https://dspace.lboro.ac.uk/2134/15108>
- [10] **Igual, R., Medrano, C. and Plaza, I.** (2013). Challenges, issues and trends in fall detection systems. *Biomed. Eng. Online*, 12(66), 1-66.
- [11] **Scuffham, P., Chaplin, S. and Legood, R.** (2003). Incidence and costs of unintentional falls in older people in the United Kingdom. *Journal of epidemiology and community health*, 57(9), 740-744.

- [12] **Rantz, M. J., Skubic, M., Abbott, C., Galambos, C., Pak, Y., Ho, D. K. and Miller, S. J.** (2013). In-home fall risk assessment and detection sensor system. *Journal of gerontological nursing*.
- [13] **Carroll, N. V., Slattum, P. W. and Cox, F. M.** (2005). The cost of falls among the community-dwelling elderly. *Journal of Managed Care Pharmacy*, 11(4), 307-316.
- [14] **Stevens, J. A., Corso, P. S., Finkelstein, E. A. and Miller, T. R.** (2006). The costs of fatal and non-fatal falls among older adults. *Injury prevention*, 12(5), 290-295.
- [15] **Pannurat, N., Thiemjarus, S. and Nantajeewarawat, E.** (2014). Automatic fall monitoring: a review. *Sensors*, 14(7), 12900-12936.
- [16] **Stevens, J. A. and Rudd, R. A.** (2014). Circumstances and contributing causes of fall deaths among persons aged 65 and older: United States, 2010. *Journal of the American Geriatrics Society*, 62(3), 470-475.
- [17] **Wang, R. D., Zhang, Y. L., Dong, L. P., Lu, J. W., Zhang, Z. Q. and He, X.** (2015, October). Fall detection algorithm for the elderly based on human characteristic matrix and SVM. In *Control, Automation and Systems (ICCAS)*, 2015 15th International Conference on (pp. 1190-1195). IEEE.
- [18] **X. Yu**, "Approaches and Principles of Fall Detection for Elderly and Patient," 10th IEEE Int. Conf. on e-health Networking, Applications and Services, Singapore, pp. 42-47, July 2008.
- [19] **Fergenson, M.** (2013). TigerPlace: An innovative 'Aging in Place' community. *AJN The American Journal of Nursing*, 113(1), 68-69.
- [20] **Stone, E. E. and Skubic, M.** (2012, May). Passive, in-home gait measurement using an inexpensive depth camera: Initial results. In *Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, 2012 6th International Conference on (pp. 183-186). IEEE.
- [21] **Aslan, M., Sengur, A., Xiao, Y., Wang, H., Ince, M. C. and Ma, X.** (2015). Shape feature encoding via fisher vector for efficient fall detection in depth-videos. *Applied Soft Computing*, 37, 1023-1028.
- [22] **Aslan, M., Alcin, O. F., Sengur, A. and Ince, M. C.** (2015, May). Fall detection with depth-videos. In *Signal Processing and Communications Applications Conference (SIU)*, 2015 23th (pp. 443-446). IEEE.

- [23] **Akagunduz, E., Aslan, M., Sengur, A., Wang, H. and Ince, M.** (2016, May) Silhouette Orientation Volumes for Efficient Fall Detection in Depth Videos. IEEE Journal of Biomedical and Health Informatics, DOI: 10.1109/JBHI.2016.2570300
- [24] **Akbulut, Y., Aslan, M., Sengur, A. and Ince, M.** (2016, March) Fall Detection with Kinect-Based Skeleton Data , International Conference on Natural Science and Engineering (ICNASE'16), (pp. 131-138)
- [25] **Gökçe-Kutsal, Y.** (2007). Yaşlanan Dünyanın Yaşlanan İnsanları (The Aging World's Aging People). Geriatri. Türk Tabipler Birliği Yayınları, Ankara, 13-19.
- [26] **Popoola, O. P. and Wang, K.** (2012). Video-based abnormal human behavior recognition—A review. Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on, 42(6), 865-878.
- [27] **Lord, S. R., Sherrington, C., Menz, H. B. and Close, J. C.** (2007). Falls in older people: risk factors and strategies for prevention. Cambridge University Press.
- [28] **Friedman, S. M., Munoz, B., West, S. K., Rubin, G. S. and Fried, L. P.** (2002). Falls and fear of falling: which comes first? A longitudinal prediction model suggests strategies for primary and secondary prevention. Journal of the American Geriatrics Society, 50(8), 1329-1335.
- [29] **Scheffer, A. C., Schuurmans, M. J., Van Dijk, N., Van Der Hooft, T. and De Rooij, S. E.** (2008). Fear of falling: measurement strategy, prevalence, risk factors and consequences among older persons. Age and ageing, 37(1), 19-24.
- [30] **Brownsell, S. and Hawley, M. S.** (2004). Automatic fall detectors and the fear of falling. Journal of telemedicine and telecare, 10(5), 262-266.
- [31] **Rubenstein, L. Z. and Josephson, K. R.** (2002). The epidemiology of falls and syncope. Clinics in geriatric medicine, 18(2), 141-158.
- [32] **Tinetti, M. E., Liu, W. L. and Claus, E. B.** (1993). Predictors and prognosis of inability to get up after falls among elderly persons. Jama, 269(1), 65-70.
- [33] **Yu, X.** (2008, July). Approaches and principles of fall detection for elderly and patient. In e-health Networking, Applications and Services, 2008. HealthCom 2008. 10th International Conference on (pp. 42-47). IEEE.

- [34] **Noury, N., Rumeau, P., Bourke, A. K., ÓLaighin, G. and Lundy, J. E.** (2008). A proposal for the classification and evaluation of fall detectors. *Irbm*, 29(6), 340-349.
- [35] **Mubashir, M., Shao, L. and Seed, L.** (2013). A survey on fall detection: Principles and approaches. *Neurocomputing*, 100, 144-152.
- [36] **Wang, K., Zhao, Y., Xiong, Q., Shen, X., Fan, M. and Gao, M.** (2015). Video Recognition of Human Fall Based on Spatiotemporal Features. *Intelligent Automation & Soft Computing*, 1-7
- [37] **Dao, H. H.** (2014). Video-based fall detection by multiview 3D spatial features PhD Theses Keio University
- [38] **Clifford, M. A., Borrás, R. L. and Gomez, L.** (2007). U.S. Patent No. 7,248,172. Washington, DC: U.S. Patent and Trademark Office.
- [39] **Lord, C. J. and Colvin, D. P.** (1991, October). Falls in the elderly: Detection and assessment. In *Engineering in Medicine and Biology Society*, 1991. Vol. 13: 1991., *Proceedings of the Annual International Conference of the IEEE* (pp. 1938-1939). IEEE.
- [40] **Williams, G. J., Doughty, K., Cameron, K. and Bradley, D. A.** (1998, October). A smart fall and activity monitor for telecare applications. In *Engineering in Medicine and Biology Society*, 1998. *Proceedings of the 20th Annual International Conference of the IEEE* (Vol. 3, pp. 1151-1154). IEEE.
- [41] **Prado, M., Reina-Tosina, J. and Roa, L.** (2002, October). Distributed intelligent architecture for falling detection and physical activity analysis in the elderly. In *Engineering in Medicine and Biology*, 2002. 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society EMBS/BMES Conference, 2002. *Proceedings of the Second Joint* (Vol. 3, pp. 1910-1911). IEEE.
- [42] **Noury, N.** (2002). A smart sensor for the remote follow up of activity and fall detection of the elderly. In *Microtechnologies in Medicine & Biology 2nd Annual International IEEE-EMB Special Topic Conference on* (pp. 314-317). IEEE.
- [43] **Degen, T., Jaeckel, H., Rufer, M. and Wyss, S.** (2003, October). SPEEDY: A Fall Detector in a Wrist Watch. In *ISWC* (pp. 184-189).
- [44] **Lin, C. S., Hsu, H. C., Lay, Y. L., Chiu, C. C. and Chao, C. S.** (2007). Wearable device for real-time monitoring of human falls. *Measurement*, 40(9), 831-840.

- [45] **Bianchi, F., Redmond, S. J., Narayanan, M. R., Cerutti, S. and Lovell, N. H.** (2010). Barometric pressure and triaxial accelerometry-based falls event detection. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 18(6), 619-627.
- [46] **Dai, J., Bai, X., Yang, Z., Shen, Z. and Xuan, D.** (2010). Mobile phone-based pervasive fall detection. *Personal and ubiquitous computing*, 14(7), 633-643.
- [47] **Dai, J., Bai, X., Yang, Z., Shen, Z. and Xuan, D.** (2010, March). PerFallD: A pervasive fall detection system using mobile phones. In *Pervasive Computing and Communications Workshops (PERCOM Workshops), 2010 8th IEEE International Conference on* (pp. 292-297). IEEE.
- [48] **Gjoreski, H., Luštrek, M. and Gams, M.** (2011, July). Accelerometer placement for posture recognition and fall detection. In *Intelligent environments (IE), 2011 7th international conference on* (pp. 47-54). IEEE.
- [49] **Zhao, Z., Chen, Y., Wang, S. and Chen, Z.** (2012). Fallalarm: Smart phone based fall detecting and positioning system. *Procedia Computer Science*, 10, 617-624.
- [50] **Bourke, A. K., Van de Ven, P., Gamble, M., O'Connor, R., Murphy, K., Bogan, E. and Nelson, J.** (2010). Evaluation of waist-mounted tri-axial accelerometer based fall-detection algorithms during scripted and continuous unscripted activities. *Journal of biomechanics*, 43(15), 3051-3057.
- [51] **Kangas, M., Konttila, A., Lindgren, P., Winblad, I. and Jämsä, T.** (2008). Comparison of low-complexity fall detection algorithms for body attached accelerometers. *Gait & posture*, 28(2), 285-291.
- [52] **Alwan, M., Rajendran, P. J., Kell, S., Mack, D., Dalal, S., Wolfe, M. and Felder, R.** (2006, April). A smart and passive floor-vibration based fall detector for elderly. In *Information and Communication Technologies, 2006. ICTTA'06. 2nd(Vol. 1, pp. 1003-1007)*. IEEE.
- [53] **Li, Y., Ho, K. C. and Popescu, M.** (2012). A microphone array system for automatic fall detection. *Biomedical Engineering, IEEE Transactions on*, 59(5), 1291-1301.
- [54] **Töreyn, B. U., Soyer, E. B., Onaran, İ. and Çetin, A. E.** (2007, June). Falling Person Detection Using Multi-sensor Signal Processing. In *Signal Processing and Communications Applications, 2007. SIU 2007. IEEE 15th* (pp. 1-4). IEEE.

- [55] **Zhuang, X., Huang, J., Potamianos, G. and Hasegawa-Johnson, M.** (2009, April). Acoustic fall detection using Gaussian mixture models and GMM supervectors. In *Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on* (pp. 69-72). IEEE.
- [56] **Igual, R., Medrano, C. and Plaza, I.** (2013). Challenges, issues and trends in fall detection systems. *Biomed. Eng. Online*, 12(66), 1-66.
- [57] **Anderson, D., Keller, J. M., Skubic, M., Chen, X. and He, Z.** (2006, August). Recognizing falls from silhouettes. In *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE* (pp. 6388-6391). IEEE.
- [58] **Huang, B., Tian, G. and Wu, H.** (2008, September). A method for fast fall detection based on intelligent space. In *Automation and Logistics, 2008. ICAL 2008. IEEE International Conference on* (pp. 2260-2265). IEEE.
- [59] **Lee, T. and Mihailidis, A.** (2005). An intelligent emergency response system: preliminary development and testing of automated fall detection. *Journal of telemedicine and telecare*, 11(4), 194-198.
- [60] **Nait-Charif, H. and McKenna, S. J.** (2004, August). Activity summarisation and fall detection in a supportive home environment. In *Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on* (Vol. 4, pp. 323-326). IEEE.
- [61] **Rougier, C., Meunier, J., St-Arnaud, A. and Rousseau, J.** (2006, August). Monocular 3D head tracking to detect falls of elderly people. In *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE* (pp. 6384-6387). IEEE.
- [62] **Cucchiara, R., Grana, C., Prati, A. and Vezzani, R.** (2005). Probabilistic posture classification for human-behavior analysis. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on*, 35(1), 42-54.
- [63] **Cucchiara, R., Prati, A. and Vezzani, R.** (2007). A multi-camera vision system for fall detection and alarm generation. *Expert Systems*, 24(5), 334-345.
- [64] **Thome, N., Miguet, S. and Ambellouis, S.** (2008). A real-time, multiview fall detection system: A LHMM-based approach. *Circuits and Systems for Video Technology, IEEE Transactions on*, 18(11), 1522-1532.

- [65] **Hazelhoff, L. and Han, J.** (2008, October). Video-based fall detection in the home using principal component analysis. In *Advanced Concepts for Intelligent Vision Systems* (pp. 298-309). Springer Berlin Heidelberg.
- [66] **Anderson, D., Luke, R. H., Keller, J. M., Skubic, M., Rantz, M. and Aud, M.** (2009). Linguistic summarization of video for fall detection using voxel person and fuzzy logic. *Computer vision and image understanding*, 113(1), 80-89.
- [67] **Zambanini, S., Machajdik, J. and Kampel, M.** (2010, November). Detecting falls at homes using a network of low-resolution cameras. In *Information Technology and Applications in Biomedicine (ITAB), 2010 10th IEEE International Conference on* (pp. 1-4). IEEE.
- [68] **Auvinet, E., Reveret, L., St-Arnaud, A., Rousseau, J. and Meunier, J.** (2008, August). Fall detection using multiple cameras. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE* (pp. 2554-2557). IEEE.
- [69] **Auvinet, E., Multon, F., Saint-Arnaud, A., Rousseau, J. and Meunier, J.** (2011). Fall detection with multiple cameras: An occlusion-resistant method based on 3-d silhouette vertical distribution. *Information Technology in Biomedicine, IEEE Transactions on*, 15(2), 290-300.
- [70] **Javed, O. and Shah, M.** (2008). *Automated multi-camera surveillance: algorithms and practice* (Vol. 10). Springer Science & Business Media.
- [71] **Edgcomb, A. and Vahid, F.** (2012). Privacy perception and fall detection accuracy for in-home video assistive monitoring with privacy enhancements. *ACM SIGHIT Record*, 2(2), 6-15.
- [72] **Stone, E. E. and Skubic, M.** (2015). Fall detection in homes of older adults using the Microsoft Kinect. *Biomedical and Health Informatics, IEEE Journal of*, 19(1), 290-301.
- [73] **Bian, Z. P., Chau, L. P. and Magnenat-Thalmann, N.** (2012, December). Fall detection based on skeleton extraction. In *Proceedings of the 11th ACM SIGGRAPH International Conference on Virtual-Reality Continuum and its Applications in Industry* (pp. 91-94). ACM.
- [74] **Ma, X., Wang, H., Xue, B., Zhou, M., Ji, B. and Li, Y.** (2014). Depth-based human fall detection via shape features and improved extreme learning machine. *Biomedical and Health Informatics, IEEE Journal of*, 18(6), 1915-1922.

- [75] **Kepski, M. and Kwolek, B.** (2014, January). Fall detection using ceiling-mounted 3d depth camera. In Int. Conf. VISAPP, pages II (pp. 640-647).
- [76] **Dubois, A. and Charpillet, F.** (2013). Automatic Fall Detection System with a RGB-D Camera using a Hidden Markov Model. In Inclusive Society: Health and Wellbeing in the Community, and Care at Home (pp. 259-266). Springer Berlin Heidelberg.
- [77] **Akagündüz, E.** (2015). Shape recognition using orientational and morphological scale-spaces of curvatures. *Computer Vision, IET*, 9(5), 750-757.
- [78] **Mokhtarian, F.** (1998). Segmenting objects at multiple scales: A robust approach. In *Computer Vision—ACCV'98* (pp. 73-80). Springer Berlin Heidelberg.
- [79] **Abbasi, S. and Mokhtarian, F.** (1999). Robustness of shape similarity retrieval under affine transformation. *Proceedings of Challenge of Image Retrieval, Newcastle upon Tyne, UK*.
- [80] **Mokhtarian, F., and Suomela, R.** (1998). Robust image corner detection through curvature scale space. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 20(12), 1376-1381.
- [81] **Mokhtarian, F. and Mackworth, A.** (1986). Scale-based description and recognition of planar curves and two-dimensional shapes. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, (1), 34-43.
- [82] **Abbasi, S. and Mokhtarian, F.** (2000, March). Multi-view object representation and recognition through curvature scale space. In *Proceedings of 5th Annual CSI International Conference* (pp. 467-476).
- [83] **Mokhtarian, F., Abbasi, S. and Kittler, J.** (1996, September). Robust and Efficient Shape Indexing through Curvature Scale Space. In *Proceedings of the 1996 British Machine and Vision Conference BMVC (Vol. 96)*.
- [84] **Mokhtarian, F., Abbasi, S. and Kittler, J.** (1997). Efficient and robust retrieval by shape content through curvature scale space. *Series on Software Engineering and Knowledge Engineering*, 8, 51-58.
- [85] **Mokhtarian, F. and Abbasi, S.** (2002). Shape similarity retrieval under affine transforms. *Pattern Recognition*, 35(1), 31-41.
- [86] **Abbasi, S., Mokhtarian, F. and Kittler, J.** (1999). Curvature scale space image in shape similarity retrieval. *Multimedia systems*, 7(6), 467-476.

- [87] **Abbasi, S. and Mokhtarian, F.** (1999). Curvature scale space with affine length parametrisation. In *Scale-Space Theories in Computer Vision* (pp. 435-440). Springer Berlin Heidelberg.
- [88] **Goetz, A.** (1970). *Introduction to differential geometry*. Addison Wesley Publishing Company.
- [89] **DurgaSreenivas, K., Reddy, C. S. and Sreenivasulu, G.** (2014). Contour Approximation Of Image Recognition By Using Curvature Scale Space And Invariant-Moment Based Method. *International Journal of Advances in Engineering & Technology*, 7(2), 359.
- [90] **Frejlichowski, D.** (2013). Application of the curvature scale space transform to the representation of three-dimensional models. *Image Processing & Communications*, 18(1), 23-29.
- [91] **Marr, D. and Hildreth, E.** (1980). Theory of edge detection. *Proceedings of the Royal Society of London B: Biological Sciences*, 207(1167), 187-217.
- [92] **Lowe, D. G.** (2004). Distinctive image features from scale-invariant key points. *International journal of computer vision*, 60(2), 91-110.
- [93] **Sánchez, J., Perronnin, F., Mensink, T. and Verbeek, J.** (2013). Image classification with the fisher vector: Theory and practice. *International journal of computer vision*, 105(3), 222-245.
- [94] **Perronnin, F., Liu, Y., Sánchez, J. and Poirier, H.** (2010, June). Large-scale image retrieval with compressed fisher vectors. In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on* (pp. 3384-3391). IEEE.
- [95] **Sivic, J. and Zisserman, A.** (2009). Efficient visual search of videos cast as text retrieval. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 31(4), 591-606.
- [96] **Filliat, D.** (2007, April). A visual bag of words method for interactive qualitative localization and mapping. In *Robotics and Automation, 2007 IEEE International Conference on* (pp. 3921-3926). IEEE.
- [97] **Jurie, F. and Triggs, B.** (2005, October). Creating efficient codebooks for visual recognition. In *Computer Vision, 2005. ICCV 2005. Tenth IEEE International Conference on* (Vol. 1, pp. 604-610). IEEE.

- [98] **Levi, G.**, "Bag of Words Models for Visual Categorization", 2013, <http://gilscvblog.wordpress.com/2013/08/23/bag-of-words-models-for-visual-categorization/>, 02 Mayıs 2016
- [99] **Wang, C. and Huang, K.** (2015). How to use Bag-of-Words model better for image classification. *Image and Vision Computing*, 38, 65-74.
- [100] **Perronnin, F. and Dance, C.** (2007, June). Fisher kernels on visual vocabularies for image categorization. In *Computer Vision and Pattern Recognition*, 2007. CVPR'07. IEEE Conference on (pp. 1-8). IEEE.
- [101] **Zhou, X., Yu, K., Zhang, T. and Huang, T. S.** (2010). Image classification using super-vector coding of local image descriptors. In *Computer Vision–ECCV 2010* (pp. 141-154). Springer Berlin Heidelberg.
- [102] **Perronnin, F., Sánchez, J. and Mensink, T.** (2010). Improving the fisher kernel for large-scale image classification. In *Computer Vision–ECCV 2010* (pp. 143-156). Springer Berlin Heidelberg.
- [103] **Burges, C. J.** (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- [104] **Gunn, S. R.** (1998). Support vector machines for classification and regression. *ISIS technical report*, 14.
- [105] **Özkan, Y.** (2008). *Veri madenciliği yöntemleri*. Papatya Yayıncılık Eğitim, 2.Baskı, Sayfa 185-195
- [106] **Fradkin, D. and Muchnik, I.** (2006). Support vector machines for classification. *Discrete methods in epidemiology*, 70, 13-20.
- [107] **Duda, R. O., Hart, P. E. and Stork, D. G.** (2012). *Pattern classification*. John Wiley & Sons.
- [108] **Fukunaga, K.** (2013). *Introduction to statistical pattern recognition*. Academic press.
- [109] **Zhang, Z., Conly, C. and Athitsos, V.** (2015, July). A survey on vision-based fall detection. In *Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments* (p. 46). ACM.
- [110] **Han, J., Shao, L., Xu, D. and Shotton, J.** (2013). Enhanced computer vision with microsoft kinect sensor: A review. *Cybernetics, IEEE Transactions on*, 43(5), 1318-1334.
- [111] **Human Interface Guidelines v1.8** <https://msdn.microsoft.com/en-us/library/jj663791.aspx> 02 Mayıs 2016

- [112] **Chen, X. and Koskela, M.** (2015). Skeleton-based action recognition with extreme learning machines. *Neurocomputing*, 149, 387-396.
- [113] **Chen, L., Wei, H. and Ferryman, J.** (2013). A survey of human motion analysis using depth imagery. *Pattern Recognition Letters*, 34(15), 1995-2006.
- [114] <http://www.sucro.org/homepage/wanghaibo/SDUFall.html> , 01 Aralık 2014
- [115] <https://sites.google.com/site/Kinectfalldetection/>, 15 Mayıs 2016
- [116] <https://sites.google.com/site/occlusiondataset>, 15 Mayıs 2016
- [117] <http://www.iro.umontreal.ca/~labimage/Dataset/>, 15 Mayıs 2016
- [118] <http://www.wisdom.weizmann.ac.il/~vision/SpaceTimeActions.html>, 15 Mayıs 2016
- [119] <http://cvrc.ece.utexas.edu/KinectDatasets/HOJ3D.html>, 15 Mayıs 2016
- [120] **Xia, L., Chen, C. C., & Aggarwal, J. K.** (2012). View invariant human action recognition using histograms of 3d joints. In *Computer Vision and Pattern Recognition Workshops (CVPRW)*, IEEE Computer Society Conference on (pp. 20-27). IEEE.
- [121] **Ding, L. and Goshtasby, A.** (2001). On the Canny edge detector. *Pattern Recognition*, 34(3), 721-725.
- [122] **Rougier, C., Meunier, J., St-Arnaud, A. and Rousseau, J.** (2011). Robust video surveillance for fall detection based on human shape deformation. *IEEE Transactions on Circuits and Systems for Video Technology*, 21(5), 611-622.
- [123] **Simonyan, K., Vedaldi, A. and Zisserman, A.** (2013). Deep fisher networks for large-scale image classification. In *Advances in neural information processing systems* (pp. 163-171).
- [124] **Peng, X., Zou, C., Qiao, Y. and Peng, Q.** (2014). Action recognition with stacked fisher vectors. In *Computer Vision–ECCV 2014* (pp. 581-595). Springer International Publishing.
- [125] <http://www.vlfeat.org/> , 01 Aralık 2014
- [126] **Yu, M. C., Naqvi, S. M., Rhuma, A. and Chambers, J.** (2012). One class boundary method classifiers for application in a video-based fall detection system. *Computer Vision, IET*, 6(2), 90-100.
- [127] **Kaufman, L. and Rousseeuw, P.** (1987). Statistical Data Analysis Based on the L1-Norm and Related Methods.

- [128] **Kaufman, L. and Rousseeuw, P.** (1987). *Clustering by means of medoids*. North-Holland.
- [129] **Blank, M., Gorelick, L., Shechtman, E., Irani, M. and Basri, R.** (2005, October). Actions as space-time shapes. In *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1* (Vol. 2, pp. 1395-1402). IEEE.
- [130] **Guo, K., Ishwar, P. and Konrad, J.** (2013). Action recognition from video using feature covariance matrices. *IEEE Transactions on Image Processing*, 22(6), 2479-2494.
- [131] **Boonbrahm, P., Sewata, L. and Boonbrahm, S.** (2015). Transforming 2D Human Data into 3D Model for Augmented Reality Applications. *Procedia Computer Science*, 75, 28-33..
- [132] **Xia, L., Chen, C. C. and Aggarwal, J. K.** (2012, June). View invariant human action recognition using histograms of 3d joints. In *Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2012 IEEE Computer Society Conference on (pp. 20-27). IEEE.
- [133] **Charaoui, A. A. and Flórez-Revuelta, F.** (2014). Optimizing human action recognition based on a cooperative coevolutionary algorithm. *Engineering Applications of Artificial Intelligence*, 31, 116-125.
- [134] **Shotton, J., Sharp, T., Kipman, A., Fitzgibbon, A., Finocchio, M., Blake, A. and Moore, R.** (2013). Real-time human pose recognition in parts from single depth images. *Communications of the ACM*, 56(1), 116-124.
- [135] **Hussein, M. E., Torki, M., Gawayyed, M. A. and El-Saban, M.** (2013, August). Human Action Recognition Using a Temporal Hierarchy of Covariance Descriptors on 3D Joint Locations. In *IJCAI* (Vol. 13, pp. 2466-2472).
- [136] **Xia, L. and Aggarwal, J. K.** (2013). Spatio-temporal depth cuboid similarity feature for activity recognition using depth camera. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2834-2841).
- [137] **Zhu, Y., Chen, W. and Guo, G.** (2013). Fusing spatiotemporal features and joints for 3d action recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 486-491).
- [138] **Yang, X. and Tian, Y.** (2014). Super normal vector for activity recognition using depth sequences. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 804-811).

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Muzaffer ASLAN

Doğum Yeri : Keban/Elazığ

Doğum Tarihi : 13/12/1969

Eğitim Durumu

Lise : Elazığ Merkez Teknik Lise (1984-1988)

Lisans : Gazi Üniversitesi Teknik Eğitim Fakültesi Elektronik Öğretmenliği
(1989-1993)

Yüksek Lisans : Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar
Eğitimi Anabilim Dalı (2002-2004)

Doktora : Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik
Mühendisliği Anabilim Dalı (2012-2016)

İş Deneyimi

1993-1995 Araklı Çok Programlı Lise

1995-2010 Gazi Endüstri Meslek Lisesi

2010-2014 Elazığ Valiliği Projeler Koordinasyon Merkezi

2014- Gazi Mesleki ve Teknik Anadolu Lisesi