

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**İVME VE DERİNLİK SENSÖR VERİLERİNİ KULLANARAK
İŞBİRLİKÇİ HAREKET VE DÜŞME TANIMA İÇİN AKILLI
TEKNİKLERİN GELİŞTİRİLMESİ**

Büşran AŞICI

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Yazılım Bilim Dalı

OCAK 2020

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**İVME VE DERİNLİK SENSÖR VERİLERİNİ KULLANARAK
İŞBİRLİKÇİ HAREKET VE DÜŞME TANIMA İÇİN AKILLI
TEKNİKLERİN GELİŞTİRİLMESİ**

Tez Yazarı
Büşran AŞICI

Danışman
Doç. Dr. İlhan AYDIN

OCAK 2020
ELAZIĞ

T. C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: İvme ve Derinlik Sensör Verilerini Kullanarak İşbirlikçi Hareket ve Düşme Tanıma için Akıllı Tekniklerin Geliştirilmesi

Yazarı: Büşran AŞICI

İlk Teslim Tarihi: 17.12.2019

Savunma Tarihi: 20.1.2020

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman: Doç. Dr. İlhan AYDIN
Fırat Üniversitesi, Mühendislik Fakültesi

İmza

Onayladım

Başkan: Dr. Öğr. Üyesi Ahmet ÇINAR
Fırat Üniversitesi, Mühendislik Fakültesi

Onayladım

Üye: Dr. Öğr. Üyesi Nuh ALPASLAN
Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi

Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Soner ÖZGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “İvme ve Derinlik Sensör Verilerini Kullanarak İşbirlikçi Hareket ve Düşme Tanıma için Akıllı Tekniklerin Geliştirilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

20/1/2020

Büşran AŞICI



ÖNSÖZ

Gelişen teknolojiyi insanların yaşamlarını kolaylaştırmak için kullanabiliriz. İnsan hareketlerinin doğru ve verimli bir şekilde tespit edilmesi ve tanımlanması, insanların ihtiyaçlarının doğru tespit edilmesine ve bu tespitler ile yaşamlarını kolaylaştıracak çalışmaların yapılmasına katkı sunabilmektedir. Mesela, özellikle yaşlılarda ciddi sağlık problemlerine sebebiyet veren düşme eyleminin doğru ve erken tespit edilmesinde ve gerekli acil ilk yardımın yapılmasında insan hareket tespitinin ve düşme tespitinin doğru ve verimli bir şekilde yapılmasının önemi oldukça büyüktür. Bu amaçla bu tez çalışmasında insan hareketlerinin tespit edilmesi ve özellikle düşen bireylere acil ilk yardımın yapılması için düşme olayının doğru ve verimli bir şekilde tespit edilmesi konularında akıllı teknikler geliştirilmiştir.

Bu çalışmada kapalı alanlardaki(ev, oda gibi) kişi hareketleri dikkate alınmıştır. Aynı zamanda ivme sensöründen ve Kinect aletinden elde edilen veriler kullanılmıştır. Yalnızca ivme verilerinden düşme eyleminin tespit edilmesi, yürüme, uzanma, merdivenden çıkma gibi günlük aktiviteleri tespit etmekten daha zordur. Çünkü düşme eylemi zıplama gibi ani hareketlerle karıştırılabilmektedir. Bu problemi aşmak için ivme verilerinden düşme olarak tespit edilen veriler, Kinect verileriyle test edilip düşmenin olup olmadığını doğrulama amacı güdüldü.

Tez çalışmalarım boyunca değerli vaktini bana ayırıp tez çalışmalarımı sürdürmem için bana yardımını, bilgisini ve desteğini esirgemeyen değerli danışmanım Sayın Doç. Dr. İlhan AYDIN' a gönülden teşekkür ederim.

Hayatımın her alanında bana desteğini ve sevgisini esirgemeyen aileme bu vesile ile en içten teşekkürlerimi sunarım.

Büşran AŞICI
ELAZIĞ, 2020

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
SİMGELER	xii
KISALTMALAR	xiii
1. GİRİŞ	1
2. HAREKET TANIMADA VE DÜŞME TESPİTİNDE KULLANILAN SENSÖRLER VE TEKNİKLER	5
2.1. Hareket Tanımada ve Düşme Tespitinde Kullanılan Sensörler	7
2.1.1. Giyilebilir Sensörler	8
2.1.2. Çevreye Yerleştirilen Sensörler.....	10
2.1.3. Giyilebilir ve Çevreye Yerleştirilen Sensör Sistemleri	14
2.2. Hareket Tanıma ve Düşme Tespitinde Kullanılan Teknikler	14
2.2.1. Sinyal İşleme.....	15
2.2.2. Hareket ve Düşme Tespitinde Çeşitli Makina Öğrenmesi Tabanlı Teknikler	15
2.2.3. Derin Öğrenme.....	20
3. MATERYAL	22
4. METOT.....	24
4.1. Hareket Tanıma için Önerilen Yöntemler	25
4.1.1. Önerilen Makine Öğrenmesi Tabanlı Hareket Tespiti.....	25
4.1.2. UKSB Tabanlı Derin Öğrenme Yöntemi ile Önerilen Hareket Tespiti Yöntemi	26
4.1.3. İnsan Hareketlerinin Tanınması için Önerilen Parçacık Sürü Optimizasyonu Tabanlı Topluluk Sınıflandırıcı Yöntemi.....	27
4.2. Düşme Eylemlerinin Tespiti için Önerilen Teknikler.....	33
4.2.1. Bir Boyutlu Yerel İkili Desen ve Aşırı Öğrenme Makinesi Yöntemleri ile Düşme Tespiti	34
4.2.2. Düşme Tespiti için Önerilen Kontrol Grafiği Yöntemi	37
5. BULGULAR VE TARTIŞMA	45
5.1. Hareket Tanıma Bulguları	45
5.1.1. Makine Öğrenmesi Tabanlı Hareket Tanıma Bulguları	45
5.1.2. UKSB Tabanlı Derin Öğrenme ile Hareket Tanıma Bulguları.....	47
5.1.3. Parçacık Sürü Optimizasyonu Tabanlı Topluluk Sınıflandırıcı ile Hareket Tespiti Bulguları	47
5.2. Düşme Tespiti Bulguları.....	53
5.2.1. 1B-YİD ve Aşırı Öğrenme Makinesi Metotları Bulguları.....	53
5.2.2. Kontrol Grafiği Metodu Bulguları	58
6. SONUÇLAR.....	64
ÖNERİLER	66

KAYNAKLAR.....	67
ÖZGEÇMİŞ.....	72



ÖZET

İvme ve Derinlik Sensör Verilerini Kullanarak İşbirlikçi Hareket ve Düşme Tanıma için Akıllı Tekniklerin Geliştirilmesi

Büşran AŞICI

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Ocak 2020, Sayfa: xiii + 71

İnsan hareketlerinin daha iyi anlaşılabilmesi için bu hareketlerin doğru ve verimli bir şekilde tespit edilmesi, tespit edilen hareketlerin de doğru bir şekilde tanımlanması ve sınıflandırılması gerekmektedir. Özellikle yaşlılarda ciddi sağlık problemlerine sebep olabilen düşme eyleminin doğru ve erken tespit edilmesi ve gerekli acil ilk yardımın yapılması gerekir. Bu amaçla bu tez çalışmasında, insan hareketlerinin tespit edilmesi ve özellikle düşen bireylere acil ilk yardımın yapılması için düşme olayının doğru ve verimli bir şekilde tespit edilmesi konularında akıllı teknikler geliştirilmiştir.

Çalışmada, Kinect derinlik verileri ile ivme verileri kullanılmıştır. Uygulamalar, MATLAB platformu üzerinden yapılmıştır. İvme verileri kullanılarak insan hareketleri ve düşme olayı tespit edilmiştir ve sınıflandırılmıştır. Zıplama gibi ani hareketler ile düşme eyleminin birbiri ile karıştırılmaması ve düşme olayının daha doğru bir şekilde tespit edilmesi için Kinect derinlik verileri, düşmenin doğrulanması için kullanılmıştır.

Öncelikle ivme verilerinden insanın günlük aktivitelerinin tespiti konusunda makine öğrenmesi teknikleri kullanılmıştır. Ek olarak Uzun Kısa Süreli Bellek (UKSB) tabanlı derin öğrenme yöntemi ile ivme verilerinden hareket tespiti yapılmış ve bu iki yöntemin sonuçları karşılaştırılmıştır. Hareket tespiti için bir sınıflandırıcıdan birden fazla sınıflandırıcı uygun bir şekilde seçilirse daha iyi sonuçların alınabileceği düşünülmüş, bu yüzden parçacık sürü optimizasyonu tekniği de uygulanmıştır. İvme verilerinden, Bir Boyutlu Yerel İkili Desen (1B-YİD) ve Aşırı Öğrenme Makinesi (AÖM) tabanlı düşme tespiti yöntemi önerilmiştir. Aynı zamanda, kontrol grafiğinin ve Kinect derinlik görüntülerinin kullanıldığı düşme tespiti tekniği geliştirilmiştir.

Sonuç olarak hareket tespiti için makine öğrenmesi algoritmaları, UKSB tabanlı derin öğrenme tekniği ve parçacık sürü optimizasyonu tekniği kullanılmıştır. Düşme tespiti için de 1B-YİD ile AÖM metotları ve kontrol grafiği metodu kullanılmıştır, etkili sonuçlar alınmıştır.

Anahtar Kelimeler: İnsan hareket tespiti, Düşme tespiti, İvme sensörü, Kinect

ABSTRACT

Development of Intelligent Techniques for Collaborative Motion and Fall Recognition Using Acceleration and Depth Sensor Data

Büşran AŞICI

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

January 2020, Pages: xiii + 71

In order to better understand human movements, these movements must be identified accurately and efficiently, and identified movements must be accurately identified and classified. Falling action, which can cause serious health problems especially in the elderly, must be detected correctly and early and necessary first aid must be provided. For this purpose, in this thesis, intelligent techniques have been developed to detect human movements and to detect the fall event accurately and efficiently in order to provide emergency first aid to falling individuals.

Kinect depth data and acceleration data were used in the study. Applications were made via MATLAB platform. Human movements and falls were detected and classified using acceleration data. Kinect depth data was used to confirm the fall to avoid confusion with sudden movements such as jumping and falling action, and to more accurately detect the fall event.

First of all, machine learning techniques were used to determine human daily activities from acceleration data. In addition, Long Short Term Memory (LSTM) based deep learning method was used to detect motion from acceleration data and the results of these two methods were compared. It is thought that better results can be obtained if more than one classifier is selected properly from a classifier for motion detection, so particle flock optimization technique has also been applied. From the acceleration data, One Dimensional Local Binary Pattern (1D-LBP) and Extreme Learning Machine (ELM) based fall detection method have been proposed. At the same time, the fall detection technique using control graph and Kinect depth images has been developed.

As a result, machine learning algorithms, LSTM based deep learning technique and particle flock optimization technique were used for motion detection. 1D-LBP and ELM methods and control graph method were used for fall detection and effective results were obtained.

Keywords: Human motion detection, Fall detection, Acceleration sensor, Kinect

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1.	İnsan aktivite tespiti ve tanımlanmasındaki genel süreç	5
Şekil 2.2.	Örnek aktivite tanıma adımları	6
Şekil 2.3.	Farklı hareketler esnasında, akıllı telefonda alınan ivme verilerinin örnek bir gösterimi	7
Şekil 2.4.	İvme ve jiroskop sensörleri görseli	8
Şekil 2.5.	Akıllı telefonlarda bulunan bazı sensörler	9
Şekil 2.6.	Oda ortamındaki kişi takibi için kullanılan bazı sensör örnekleri	10
Şekil 2.7.	Akustik (ayak sesi) sinyalleri kullanarak önerilen düşme algılama sisteminin blok diyagramı	11
Şekil 2.8.	Gömülü bir bilgisayar ve kamera içeren model diyagramı	12
Şekil 2.9.	Kinect kamera ile düşme tespiti yöntemi	13
Şekil 2.10.	Kwalek ve Kepski'nin düşme tespitinde önerdikleri, Kinect ve ivmeölçer tabanlı model	14
Şekil 2.11.	Makine öğrenmesi çeşitleri	16
Şekil 2.12.	Kümeleme ile verilerden gizli kalıpların bulunması	17
Şekil 2.13.	Bazı Makine Öğrenmesi teknikleri	18
Şekil 2.14.	Doğrusal Destek Vektör Makinesi gösterimi	18
Şekil 2.15.	En yakın komşu gösterimi	19
Şekil 2.16.	Topluluk Sınıflandırma Tekniği	20
Şekil 2.17.	Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme arasındaki kapsam ilişkisi	21
Şekil 2.18.	Üç gizli katmanlı olan bir derin öğrenme sinir ağı	21
Şekil 3.1.	Matlab Sınıflandırma Öğrenici (Classification Learner) arayüzü	23
Şekil 4.1.	Hareket ve düşme tespiti için kullanılan metodlar	24
Şekil 4.2.	İvme verilerinin makine öğrenmesi yöntemleri ile test edilme aşamaları	25
Şekil 4.3.	İvme verileri ile aktivite tanıma süreci	26
Şekil 4.4.	UKSB mimarisi	27
Şekil 4.5.	Parçacık sürü optimizasyonu algoritması	29
Şekil 4.6.	Tek parçacık için hız ve konum güncellemelerinin iki boyutlu, geometrik gösterimi	29
Şekil 4.7.	Parçacık sürü optimizasyonu tabanlı topluluk sınıflandırıcı	30
Şekil 4.8.	Yürüme ve merdiven çıkma hareketleri için frekans spektrumları	31
Şekil 4.9.	Düşme olayını bulmak için önerilen 1B-YİD ve AMÖ metodlarının iş akışı	34
Şekil 4.10.	2B-YİD kodunun hesaplanması	35
Şekil 4.11.	Nöronlar ile basit bir tek gizli katmanlı yapay sinir ağı	36
Şekil 4.12.	Yapay Sinir Ağı'nın Matematiksel Gösterimi	36

Şekil 4.13.	Aykırı noktaları gösteren örnek kontrol grafiği	39
Şekil 4.14.	Çok büyük boyuttaki bazı günlük normal aktivite verilerinin R kontrol grafiği sonuçları	40
Şekil 4.15.	Düşme tespiti işlemlerinin genel taslağı	41
Şekil 4.16.	Arkaplan çıkarımı yapılmış ikili resim ve tespit edilen kişiyi sınırlayan kutunun gösterimi ...	42
Şekil 4.17.	Sandalyeden düşme eyleminin zamana göre ikili resme (en üstteki), derinlik görüntüsüne (ortadaki) ve renkli görüntüye (en alttaki) göre gösterimi	42
Şekil 4.18.	Bir düşme aktivitesinin çıkarılmış özelliklerinin birbirleri ile karşılaştırılan dağılım grafikleri	43
Şekil 4.19.	Bazı düşme aktivitelerinin R kontrol grafiği sonuçları	44
Şekil 4.20.	Bazı günlük aktivitelerinin R kontrol grafiği sonuçları	44
Şekil 5.1.	Torbalı Ağaç modeli verimlilik sonuçları	46
Şekil 5.2.	Torbalı Ağaç modeli gerçek sınıflar ile tahmin edilen sınıf veri sayıları kıyaslaması	46
Şekil 5.3.	UKSB ağı ile kişi hareketi tahmin grafiği.....	47
Şekil 5.4.	Farklı hareketler için üç eksen ivme sinyalleri	48
Şekil 5.5.	Beş farklı sınıflandırıcının karmaşıklık matrisi	49
Şekil 5.6.	Parçacık sürü optimizasyonun	50
Şekil 5.7.	Farklı performans ölçümlerine göre algoritmaların başarımları	51
Şekil 5.8.	Üç eksen ivme verilerinin grafikleri ve sandalyeye oturma eylemi için onların büyüklük grafiği.....	53
Şekil 5.9.	Dört farklı günlük aktivitenin ivme büyüklüklerinin grafikleri	54
Şekil 5.10.	Bazı düşme aktiviteleri büyüklük grafikleri.....	54
Şekil 5.11.	Bazı normal aktivitelerin 1B-YİD ivme verileri ve histogram grafikleri.....	55
Şekil 5.12.	Bazı düşme aktivitelerinin ivme verisi grafikleri ile histogram grafikleri	56
Şekil 5.13.	Bazı günlük aktivitelerin ivme ve açısal hız grafikleri	59
Şekil 5.14.	Düşme eyleminin ivme ve açısal hız grafikleri.....	59
Şekil 5.15.	70 farklı düşme ve günlük aktivitelerin kontrol grafiği sonucunda elde edilen aykırı noktalarını gösteren bar grafiği	61
Şekil 5.16.	İyi Gauss DVM algoritmasının doğru pozitif ve yanlış negatif oranları karmaşıklık matrisi	62
Şekil 5.17.	İyi Gauss DVM algoritmasının olumlu tahmin değeri ile yanlış keşif oranı karmaşıklık matrisi sonuçları.....	62

TABLÖLAR LİSTESİ

	Sayfa
Tablo 4.1. Altı sınıflandırıcı için üç parçacıklı parçacık sürü optimizasyon kodlaması	32
Tablo 4.2. Çoğunluk oylama ile sınıflandırma.....	33
Tablo 5.1. Bazı örnek sınıflandırma modellerinin doğruluk sonuçları.....	45
Tablo 5.2. Torbalı Ağaç Sınıflandırma Modeli için Tahmin Verilerinin Test Verilerine Göre Doğruluğu	47
Tablo 5.3. İvme verilerinden elde edilen özellikler.....	48
Tablo 5.4. Ayırık parçacık sürü optimizasyonun parametreleri	50
Tablo 5.5. Parçacık sürü optimizasyonu ve çoğunluk oylama tabanlı hareket tanıma yönteminin karmaşıklık matrisi	51
Tablo 5.6. Önerilen yöntemin farklı yöntemler ile karşılaştırma sonuçları.....	52
Tablo 5.7. AÖM ve DVM ile YSA Sınıflandırıcıların doğruluk sonuçları	56
Tablo 5.8. Önerilen AÖM yöntemi ile elde edilen doğruluk sonucu ve literatürdeki bazı çalışmaların karşılaştırılması	57
Tablo 5.9. Potansiyel düşme verilerinin makine öğrenmesi algoritmaları ile eğitilmeleri sonucunda elde edilen doğruluklar	63

SİMGELER

c_1, c_2	: Pozitif sabit değerler
C_t	: Mevcut hücre hafızası
C_{t-1}	: Önceki hücre hafızası
d	: Boyut; c_1 ve c_2
f_t	: Unutma kapısı (forget gate)
gb_j	: Bütün popülasyon içinde j
H_t	: Önceki hücre çıktısı
H_{t-1}	: Önceki hücre çıktısı
I_t	: Giriş kapısı (input gate)
i	: Parçacık sayısı
N	: Toplam parçacık veya eleman sayısı
O_t	: Çıktı kapısı (output gate)
$pb_{i,j}$	: i. parçacığın j boyutu için şu ana kadar ki en iyi pozisyonu
r_1	: Bilişsel ölçekleme
r_2	: Sosyal ölçekleme
$\tanh$	: Hiperbolik tanjant
U	: Kapı (gate) ağırlığı
$v_{i,d}$	: $V(i)$ hız vektörünün boyutu
w	: Atalet ağırlığı
W	: Kapı (gate) ağırlığı
$x_{i,j}$	: 0 veya 1
X_t	: Girdi vektörü
ψ	: Atalet momenti ($0 < \psi < 1$)

KISALTMALAR

1B-YİD	: Bir Boyutlu Yerel İkili Desen
1D-LBP	: One Dimensional Local Binary Pattern
AÖM	: Aşırı Öğrenme Makinesi
Acc_X	: X eksenindeki ivme değeri
Acc_Y	: Y eksenindeki ivme değeri
Acc_Z	: Z eksenindeki ivme değeri
AKL	: Alt Kontrol Sınır
CCD	: Charge Couple Device
KDVM	: Kübik Destek Vektör Makineleri
DVMC	: Kübik Destek Vektör Makineleri
CNN	: Convolutional Neural Network
DVM	: Destek Vektör Makineleri
ELM	: Extreme Learning Machine
GDVM	: Gauss Destek Vektör Makineleri
DVMG	: Gauss Destek Vektör Makineleri
GPS	: Global Positioning System
KA	: Karar Ağacı
KEYK	: K-En Yakın Komşu sınıflandırıcı
KNN	: K-Nearest Neighbor
PSO	: Parçacık Sürü Optimizasyonu
R	: Range,(Aralık, yayılma aralığı)
RGB	: Red Green Blue
SVM	: Support Vector Machine
UKSB	: Uzun Kısa Süreli Bellek
ÜKL	: Üst Kontrol Sınır
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Gelişen teknolojiyi insanların hareketlerinin ve özellikle düşme eyleminin tespiti için kullanabiliriz ve böylelikle insanların yaşamlarını kolaylaştırabiliriz. Yaşlılarda ciddi yaşamsal problemlere sebep olabilen düşme eyleminin doğru ve hızlı bir şekilde tespit edilmesi, düşen yaşlılara zamanında gerekli yardımın ve tedavinin yapılması için oldukça önemlidir. İnsan hareketlerinin ve düşme eyleminin doğru tespit edilmesi ve düşen bireylere gerekli tedavinin zamanında ve hızlı bir şekilde ulaştırılmasına katkıda bulunmak amacıyla bu tez çalışması yapılmıştır. Yalnızca ivme verilerinin kullanılması ile düşme aktivitelerinin, düşme olmayan zıplama, dans etme gibi bazı günlük aktiviteler ile karıştırılabileceğini varsayarak Kinect verilerinin düşmenin eyleminin doğrulanmasında kullanılabileceği, kabul edilmiştir.

Literatürü incelediğimizde çalışmalar kullanılan sensör ve sistemler bakımından genel olarak üçe ayrılır. Bunlar, giyilebilir sensörler ile oluşturulan sistemler, çevreye yerleştirilen sensörler ile oluşturulan sistemler ve bu ikisinin bir arada olduğu sistemlerdir. Giyilebilir sensörler ile yapılmış birçok hareket tespiti çalışmalarını görebiliriz. Karantonis ark. [3], bele bağlı üç eksenli tek bir ivme sensörüyle elde edilen verileri kullanarak insan hareketlerini gerçek zamanlı tespit eden bir sistem geliştirmişlerdir. Gao ve ark. [4], göğüs, bel, uyluk ve sol kol altına yerleştirilen dört ivmeölçer ile çoklu sensörlerden oluşan bir sistem geliştirmişlerdir. Burada amaç hafif sinyal işleme algoritmaları ile yüksek tanıma doğruluğu sağlamaktır. Bu çalışmada beş sınıflandırıcı (Yapay Sinir Ağı, Karar ağaçları, K-En Yakın Komşu, Naif Bayes ve Destek Vektör Makineleri), dizüstü bilgisayardaki WEKA yazılımı kullanılarak karşılaştırılmıştır. Akıllı telefonun ivme ve jiroskop sensörlerinden elde ettiği verilerle, Ronao ve Cho [5], iki aşamalı sürekli bir gizli Markov modeli ile aktivite tanıma yaklaşımı sunmuştur. Dernbach ve ark. [6] ise basit hareketlerin dışında, yemek pişirme, temizlik yapma gibi karmaşık aktiviteleri akıllı telefon ile tanıma üzerine bir çalışma yapmışlardır. Basit aktiviteler kolayca tanınırken karmaşık modellerde tahmin performansının düşük olduğunu ortaya koymuşlardır. Aydın [7] ise insan aktivitesi tanımda akıllı telefon verileri ile guguk kuşu arama için optimize edilen bulanık integral kaynaştırmalı bir yöntem önermiştir. Burada Lineer Ayırt Edici Analiz, Destek Vektör Makineleri (DVM) ve sinir ağı sınıflandırma metotlarının sonuçlarını yüksek bir sınıflandırma performansı ile birleştiren ve sınıflandırıcılardan, bulanık integral için uygun sınıfı gelen örneğe göre belirleyen bir yöntem önerilmiştir. Sonuç olarak, iyi sınıflandırıcıların birleştirilmesi ile eylem tanıma başarısının arttığı gösterilmiştir. Giyilebilir sensörlerle düşme tespiti çalışmaları da yapılmıştır. Mesela, Huynh ve arkadaşları [8], göğüsün merkezine yerleştirilen, üç eksenli ivmeölçer ve jiroskoptan oluşan giyilebilir sensör sistemine dayalı ivme ve açısal hız verileri toplanarak optimize edilmiş bir düşme tespit algoritması geliştirmişlerdir. Çalışmalarında, ivme ve açısal hız verilerinin toplanmasıyla optimize edilmiş bir düşme tespit algoritması geliştirilmiştir ve düşmeyi saptamak için kritik düşme

eşik değerleri kullanılmıştır. S. V. Georgakopoulos ve arkadaşları [9], mobil cihazların ivmeölçerleri ile gerçek zamanlı düşüş tespiti üzerine bir çalışma yapmışlardır. Toplam istatistiksel veri madenciliği algoritması ile sinyal değişimi tespiti kullanılarak düşmeler tespit edilmiştir.

Çevreye yerleştirilen sensörler ile kişi uzaktan, üzerinde bir sensör taşımak zorunda kalmadan takip edilebilir. Bu bakımdan konforlu ve kullanışlıdır. Çevreye yerleştirilen sensörlere, kameralar, kızılötesi sensörler, basınç sensörleri, mikrofon ve zemin sensörleri örnek olarak verilebilir. Kameraların ve görüntü işleme yöntemlerinin gelişmesi ile kamera ve görüntü tabanlı kişi takibi ve kişilerin hareketlerinin analiz edilmesi için yapılan çalışmalar, son zamanların önemli araştırma konuları arasındadır. Görsel sistemler ile hareket tanımayı, akıllı evlerde, sağlık takibi sistemlerinde, kamu alanlarında güvenlik ve gözetim sistemlerinde, spor ve açık alanlar gibi birçok alanda görebiliriz [10]. Chaccour ve Darazi [11], yaşlı düşme tespiti için basit bir akıllı halı geliştirmişlerdir. Bu halıda basınç sensörleri kullanılmıştır. Khan ve ark. [12], yaşlı bir kişinin normal aktivitelerinden toplanan akustik sinyalleri (ayak sesi sinyallerini) kullanarak düşmeleri, düşme olmayan verilerden ayırt eden bir veri tanımlama modeli oluşturmak için denetimsiz düşme tespit sistemi sunmuşlardır. Çevreye yerleştirilen sensör sisteminde kullanılan aletlerden biri de kameralardır. Kamera tabanlı sistemler ile kişi, uzaktan izlenebilir ve hareket tespiti yapılabilir. Bu sistemler, vücutta sensör taşımayı gerektirmediğinden izlenen kişi için konforludur. Görsel tabanlı kişi takibi gizlilik, güvenlik, gözetim, spor ve düşme tespiti alanlarında yaygın olarak kullanılmaktadır [13, 14, 2]. Emonet ve ark. [15], metro gibi açık alanda, aykırılık tespiti için çoklu kameralar ile insan aktivite tanınması yapmışlardır. Ryoo [16], çalışmasında tamamlanmış aktivitelerin aksine bitmemiş faaliyetlerin, videolar ile erken tespiti üzerine çalışmıştır. Miville ve ark. [17], kamera tabanlı bir sistem geliştirmişlerdir. Çalışmalarında, arka plan çıkarıcı, Kalman Filtresi ve optik akış, düşme olaylarını tanımlamak için makine öğrenmesine girdi olarak birleştirilir. Kontrollü ortamlarda, sistem, % 96 doğruluk oranında çalışır. Burada, kameranın sınırlı çözünürlüğü nedeniyle, özne ile kamera arasında 10 m'den daha uzun bir mesafe olması arzu edilmez. Düşme tespiti için sürekli taşınmayı gerektiren ivme sensörü kullanıcıyı rahatsız edebilir. Renkli kamera tabanlı düşme algılama sistemleri de izlenen kişide mahremiyetin korunması bakımından rahatsızlığa sebep olabilir. Bu zorluklara karşı Khan ve ark. [12], akustik sensörü tabanlı bir sistem önermişlerdir. Çalışmalarında iki mikrofon ve kaynak ayırma metodu önermişlerdir. Arka plandaki seslere olan direnç, diğer ses kaynaklarının neden olduğu parazitlerin kaynak ayırma yöntemi ile kaldırılmasıyla arttırılmıştır.

Son zamanlarda görüntü işleme tabanlı kişi tespitinde, Kinect sensörleri oldukça önemli bir yere sahiptir. Kinect sensörleri ile derinlik verileri alınabilmektedir. RGB kameralardan alınan renkli görüntülere göre derinlik görüntüleri mahremiyetin korunması açısından oldukça avantajlıdır [2]. Aynı zamanda düşme riski taşıyan bireylerin aktivitelerinin takibi için renkli görüntü alan kameraların kullanılması, izlenen bireylerin rahatsız hissetmelerine sebep olabilir, onları günlük

aktiviteleri yapmaktan alıkoyabilir. Gerekli aktivitelerin azaltılması, aktivite yetersizliğinden kaynaklanan güç zayıflığı ve güçsüzlük de düşmeye sebep olabilmektedir. Düşme olayı, kişilerde düşme korkusu ile sonuçlanabilmektedir [18]. Derinlik görüntüleri ile kişi takibi, düşme korkusunun önüne geçmede, pozitif etkiye sahiptir. Lei Yang ve ark. [19], oda ortamında Kinect sensörü kullanılarak elde edilen derinlik görüntüleri ile düşme saptama çalışması yürütmüştür. Derinlik görüntüleri, medyan filtreleme ile önceden işlenir. Arka plan çerçevelerinden basit bir çıkartma ile hareketli kişinin silueti elde edilir. Düşme olayını bulmak için, insan vücudunun merkezi ve insan bedeni ile yer arasındaki açı hesaplanır. Bu hesaplanan değerler, bazı eşik değerleri aşarsa bir düşüş olayı algılanır. Yalnızca derinlikli görüntülerin kullanılması, izlenen kişinin mahremiyetinin korunmasında önemli bir rol oynayabilir. Fakat burada eşik değeri doğal bir seçim olduğundan, eşik değerinin ne kadar uygun seçildiği tartışmaya açıktır.

Giyilebilir sensörler ve çevreye yerleştirilen sensörlerin birleşimi ile kişilerin normal aktiviteleriyle düşme aktivitelerini birbirinden ayırmak için birçok çalışma yapılmıştır. Bunlara Kepski ve Kwolek'in [2, 20, 18, 21], Kinect ve ivme verilerini kullanarak yapmış oldukları çalışmalar örnek olarak verilebilir. Kwolek ve Kepski [21], Kinect sensörünü ve vücuda monte edilen ivmeölçeri kullanan bulanık çıkarımı temel alan bir düşme algılama yöntemi önermişlerdir. Düşme olayını doğrulamak için bulanık bir sistem ve potansiyel bir düşme durumunda bu sistemi başlatmak için eşik tabanlı bir algoritma kullanılmıştır. Verimli sonuçlar gösterilmiştir.

Düşme eylemi sonrası meydana gelebilecek yaralanmalara ve sağlık problemlerine hızlı ve verimli ilk yardımın ulaştırılması için düşme tespitin doğru bir şekilde yapılması gerekmektedir. Düşme eylemi özellikle yaşlılarda ciddi yaşamsal problemlere sebep olabilmektedir. Çalışmamız düşmenin sebep olduğu problemlerin çözülmesi için ilk adım olan insan hareket tespiti ve düşme tespiti konularında farklı yaklaşımlar ve teknikler sunmaktadır. Bu çalışma insanların hareketlerini ve düşme eylemini doğru ve verimli bir şekilde tespit etmek ve bu konuda çalışma yapmak isteyenlere fikir verebilir.

Bu tez çalışmasında insan aktivitesini tanımak ve düşme tespiti yapmak için birçok teknik geliştirilmiştir. Kişi hareket tespiti yapmak için üç yöntem önerilmiştir. Birinci yöntem, Makine Öğrenmesi algoritmaları kullanarak hareket tespiti yapmaktır. Hareket tespiti için önerilen ikinci yöntem, Uzun Kısa Süreli Bellek (UKSB) tabanlı derin öğrenme yöntemidir. Üçüncüsü ise Parçacık Sürü Optimizasyonu tabanlı topluluk sınıflandırıcı yöntemi ile hareket tespitidir. Hareket tespitinin dışında düşme tespiti için de farklı yöntemler önerilmiştir. Bu yöntemlerin ilki, yalnızca ivme verilerinin kullanıldığı, 1 Boyutlu Yerel İkili Desen (1B-YİD) ve Aşırı Öğrenme Makinesi (AÖM) yöntemleri ile düşme tespitidir. İkincisi, ivme verilerinden kontrol grafiği fonksiyonu ile potansiyel düşmelerin tespiti ve bulunan potansiyel düşmelerin ilgili Kinect verilerine gidilip düşmenin olup olmadığının doğrulanmasına dayalı düşme tespiti yöntemidir. Aynı zamanda bu teknikleri geliştirmek için birçok veri kümesi kullanılmıştır [1, 2].


Akıllı telefonda alınan ivme verileriyle yürüme, durma, oturma, koşma gibi günlük aktiviteler makine öğrenmesi teknikleri ve UKSB tabanlı derin öğrenme tekniği ile tespit edilmiş ve karşılaştırılmıştır. Hareket tespiti için bir başka kullandığımız teknik ise parçacık sürü optimizasyonu tekniğidir. Parçacık sürü optimizasyonunun kullanılma amacı, büyük veri kümeleri üzerinde tek bir sınıflandırıcı ile yüksek başarımın elde edilmesi çoğu zaman zordur. Birden fazla sınıflandırıcının uygun şekilde birleştirilmesi ile daha yüksek başarımlar elde edilebilir. Bu çalışma kapsamında önerilen topluluk seçim yöntemi, parçacık sürü optimizasyonu tabanlı bir topluluk kullanarak bir araya getirilmekte ve sınıflandırma performansını en fazla arttıran en iyi sınıflandırıcı grup otomatik olarak seçilmektedir.

Yalnızca ivme verileriyle 1B-YİD ve AÖM yöntemleri kullanılarak düşme tespiti yapılmıştır. Burada, 1B-YİD yöntemi ile özellik çıkarımı yapılmıştır ve özellik çıkarımı yapıldıktan sonra AÖM metodu ile veriler eğitilmiştir. Elde ettiğimiz sonuçlar literatürde yapılmış olan bazı çalışmalarla karşılaştırıldı ve oldukça iyi sonuçlar elde ettiğimiz ortaya konulmuştur. Bir diğer düşme tespiti çalışmasında hazır ivme ve Kinect verileri kullanılmıştır [2]. İvme verilerinden düşme anları, kontrol grafiği metoduyla tespit edilmiştir. Kontrol grafiği fonksiyonu ile belli bir süre devam eden harekette meydana gelen ani değişiklikler, kontrol limiti geçen aykırı noktaların bulunması ile kolaylıkla elde edilebilmektedir. Çalışmada, bulunan aykırı noktalar potansiyel düşme anları olarak kabul edilmiştir. Ve bu hareket anlarına yakın aralıkta elde edilen Kinect görüntülerine gidilip düşmenin olup olmadığı doğrulanmıştır.

Tez, giriş bölümü ile başlamaktadır. Bu bölümde insan hareket tespiti ve düşme tespitinin öneminden, tezin amacından ve tezde kullanılan metotlardan ve literatür bilgisinden kısaca bahsedildi. İkinci bölümde hareket tanıma ve düşme tespiti için kullanılan sensörler ve teknikler detaylı olarak anlatılmıştır. Üçüncü bölümde, tez çalışmasında kullanılan materyaller anlatılmıştır. Bir sonraki bölümde insan hareket tanıma ve düşme tespiti için önerilen ve kullanılan metotlar verilmiştir. Beşinci bölümde elde edilen bulgular detaylı bir şekilde verilmiştir. Sonuç bölümünde, tez çalışmasında elde edilen sonuçlar ve bilgiler verilmiştir.


2. HAREKET TANIMADA VE DÜŞME TESPİTİNDE KULLANILAN SENSÖRLER VE TEKNİKLER

İnsan aktivite tanımı, insanların hareketlerinin yorumlanıp sınıflandırılmasıdır [22]. İnsanların hareketlerinin yorumlanabilmesi için öncelikle sensörler veya aletler ile insanların hareketlerini algılayan sistemler gerekmektedir. Kullanılan sensör ile toplanan veriler, çeşitli algoritmalarla, makine veya derin öğrenme gibi teknikler ile işlenir ve aktiviteler sınıflandırılır ve böylelikle aktivitelerin tanımı elde edilir. Sıklıkla tespit edilen basit aktiviteler, yürüme, koşma, uzanma, merdivenden çıkma veya inme gibi aktivitelerdir [23, 10]. Yaşlılarda görülen düşme eyleminin tespit edilmesi de son zamanlarda araştırılan önemli bir konudur [12, 21, 24, 25]. Giyilebilir sensörler özellikle akıllı evlerde ve sağlık sistemlerinde kullanılmaktadır [26]. Şekil 2.1’de sensörlerle aktivite tanımadaki temel süreç verilmiştir.



Şekil 2.1. İnsan aktivite tespiti ve tanımlanmasındaki genel süreç

Hareket tanımda izlenen adımlardan bazıları: veri toplama, veri ön işleme, bölümleme, özellik çıkarımı ve sınıflandırmadır [27]. Veri toplamada, kullanılacak sensör belirlenir, kurulumun ardından veriler sensör ile toplanır. Veri ön işleme adımı ise kullanılan verileri analiz için uygun ve kullanılabilir duruma getirme işlemlerini içerir. Bu işlemlere, birim dönüşümü, normalleştirme, eksik ve bozuk verilerin düzeltilmesi örnek olarak verilebilir. Veri bölümlenmesi ile hareket tanımda sonraki adımlara aktarılan verilerin boyutu azaltır. Özellik çıkarımı ise orijinal verinin en ayırt edici bilgileri içeren azaltılmış sayıdaki değişkenlere dönüştürülmesi işlemidir [23]. Çıkarılan özellikler ile bir sınıflandırıcı oluşturulur [27]. Şekil 2.2’ de aktivite tanıma adımlarına örnek bir gösterim sunulmuştur.




Şekil 2.2. Örnek aktivite tanıma adımları

Hareket tespiti ve tanımda kullanılan sistemler genellikle üçe ayrılmaktadır:

- Giyilebilir sensörler ile oluşturulan sistemler
- Çevreye yerleştirilen sensörler ile oluşturulan sistemler
- Giyilebilir ve çevreye yerleştirilen sensörlerin bir arada olduğu sistemler

Üç eksenli ivme sensörleri, jiroskop, manyetometre sensörleri, akıllı telefonlar, akıllı saatler ve akıllı gözlükler giyilebilir sensörlere örnek olarak verilebilir [28]. Akıllı telefonlar, insan aktivitesini tanımda sıklıkla kullanılan ivme sensörü ile jiroskop sensörünü bir arada bulundurması bakımından oldukça avantajlıdır. Akıllı telefonları kullananlar için bir diğer avantaj ise telefonun içerisinde bulunan sensörleri ek olarak almalarına gerek olmamasıdır ve böylelikle ekonomik olarak da avantajlıdır. Şekil 2.3'te farklı hareketler esansında ivme sensöründen alınan sinyaller gösterilmiştir.



Şekil 2.3. Farklı hareketler esnasında, akıllı telefonda alınan ivme verilerinin örnek bir gösterimi

Çevreye yerleştirilen sensörler ile kişi uzaktan, üzerinde bir sensör taşımak zorunda kalmadan takip edilebilir. Bu bakımdan konforlu ve kullanışlıdır. Kameraların ve görüntü işleme yöntemlerinin gelişmesi ile kamera ve görüntü tabanlı kişi takibi ve kişilerin hareketlerinin analiz edilmesi için yapılan çalışmalar, son zamanların önemli araştırma konuları arasındadır. Görsel sistemler ile hareket tanımayı; akıllı evlerde, sağlık takibi sistemlerinde, kamu alanlarında güvenlik ve gözetim sistemlerinde, spor ve açık alanlar gibi birçok alanda görebiliriz [10].

Son zamanlarda dikkat çeken araştırma konularından biri de Kinect sensörü ile kişinin taşıdığı ivme sensöründen alınan ivme verilerinin bir arada kullanıldığı sistemlerdir [21]. Kamera her ışık koşullunda etkili görüntü elde edemeyebilir ve bu yüzden derinlik görüntülerini alan Kinect gibi aletlerin kullanımı ile zor aydınlatma koşullarında dahi daha etkili hareket tespiti yapılması mümkün olmuştur.

2.1. Hareket Tanıma ve Düşme Tespitinde Kullanılan Sensörler


Hareket tanıma kullanılan sensörler genellikle vücuda takılabilen veya giyilebilen sensörler ile çevreye yerleştirilen (vücuda takılma ya da vücutta taşınmayı gerektirmeyen) sensörlerdir. Giyilebilir sensörlere üç eksenli ivme sensörleri, jiroskop, manyetometre sensörleri, akıllı telefonlar, akıllı saatler ve akıllı gözlükler örnek olarak verilebilir. Çevreye yerleştirilen sensörlere veya aletlere örnek olarak da basınç sensörü, mikrofön, kızılötesi sensörü, Kinect aleti ve kameralar verilebilir. Hareket tespiti için çokça kullanılmış olan sensörler ivme sensörleri ile jiroskop sensörüdür. Giyilebilir ivme sensörlü sistemlerdeki temel mantık belirlenen eşik değeri ile eylemin (mesela düşme eylemi) tespit edilmesidir [29]. Zamanla akıllı telefonlar gelişmekte ve birçok akıllı telefonun ivme veya jiroskop gibi sensörleri barındırması ile akıllı telefonlar da hareket veya düşme tespiti için kullanılmaktadır.

2.1.1. Giyilebilir Sensörler

Giyilebilir sensörler, vücutta taşınmayı gerektiren sensörlerdir. İvme sensörleri, jiroskoplar, akıllı telefonlar, akıllı saatler, akıllı gözlükler giyilebilir sensörlere örnek olarak verilebilir.

İvme Sensörü ve Jiroskop

Üç eksenli ivme sensörü ile hareketli cismin, x, y ve z yönlerindeki ivme verileri elde edilmektedir. Jiroskoplar, bir çerçeveye monte edilen ve bu çerçeve dönüyorsa onun açısız hızını algılayan aletlerdir [30]. Şekil 2.4'te ivme ve jiroskop sensörlerinin örnek bir görseli bulunmaktadır. İvme sensörleri ve jiroskoplar, düşme olaylarını tespit etmede birçok araştırmada kullanılmış aletlerdir [31, 32, 33]. Mesela, Bourke ve ark. [31], gövdede ve uylukta monte edilen üç eksenli ivmeölçerden gelen sinyallerle; düşmeler ile günlük aktiviteler arasında otomatik olarak ayırım yapabilen eşik tabanlı bir algoritma geliştirmişlerdir. Sonuç olarak üst düşme eşik değeri için genel özgülük değerleri, gövdede % 100 ve uylukta ise % 83,3 olarak beyan edilmiştir. Doukas ve arkadaşlarının [34] çalışmasında, ivmeölçer verileri hasta hareket verilerini izleme ünitesine kablosuz olarak iletilir. Üç eksenindeki ivme verileri, Destek Vektör Makinesi kullanılarak sınıflandırılmıştır. Burada düşüş şüphesi varsa, video görüntüleri, uzaktan izleme birimlerine iletir. Ortalama % 98,2 doğrulukta düşme olayları saptanmıştır. Li ve ark. [32], hem ivmeölçerler hem de jiroskoplar kullanarak düşme algılama sistemi geliştirmiştir.




Şekil 2.4. İvme ve jiroskop sensörleri görseli

İvme sensörünün avantajı, üç eksenli verileri elde etmede, düşük maliyetli olmasıdır. Fakat sürekli kişi takibinde, uzun süre vücutta taşınmayı gerektiren durumlarda (mesela düşme takibi) rahatsızlık verebilir ve vücudunda taşıyan bireyin konforunu olumsuz etkileyebilmektedir. Bazı

arařtırmalarda [35] sensörün kiřinin göğüs hizasında kullanılması önerilmiřtir. Bu tarz durumlarda kiři kıyafetini deęiřtirirken veya banyo yapmada problemler yařayabilir. Bu problemlerin önüne geçebilmek için su geçirmez ve ierisinde ivme sensörü barındıran akıllı saatlerin kullanımı düşünölebilir. Fakat yalnızca ivmeöler ile kiři düşmelerinin tespiti birçok yanlış alarmlarla sonuçlanmaktadır [36]. İvmeölerin hızla deęiřen ortam kořullarına adaptasyonunun zayıf olması ve günlük aktiviteler ile gerek düşmeyi tam olarak ayıramaması, ivme sensörünün dezavantajı olarak gösterilebilir. İvme sensörü kullanılarak eřik deęer ile hareket tespitinin yapıldıęı alıřmalarda, her aktivite doęru bir řekilde ayırt edilemeyebilir. Mesela düşme ile bazı günlük aktiviteler birbirinden tam olarak ayırt edilemeyebilir. ünkü düşme eylemi ani gerekleşen bir olaydır ve uygun eřik deęerini geen aktivitenin düşme aktivitesi olduęu söylenilebilir. Fakat kanepeye hızla oturma veya zıplama gibi günlük aktiviteler de eřik deęerini geebilir ve düşme olarak algılanabilir. Bu yüzden eřik deęerinin kullanıldıęı ivme sensörü ile yapılan alıřmalarda her aktivite doęru bir řekilde ayırt edilemez [36].

Akıllı telefonlar

Geliřen teknoloji ile artık akıllı telefonlar, ivmeöler, dijital pusula, jiroskop, GPS (Global Positioning System), mikrofon ve kamera gibi sensörleri ierebilmektedirler. řekil 2.5'te akıllı telefonda bulunabilecek sensör örnekleri verilmiřtir.




řekil 2.5. Akıllı telefonlarda bulunan bazı sensörler

Özellikle ivmeöler ve jiroskop sensörlerini iinde bulundurması sebebiyle, düşme olayını tespit etmek için yapılan birçok alıřmada kullanılmıřlardır. Mesela, Abbate ve ark. [37], hasta hareketlerini izlemek, düşmeyi tanımak ve bakıcılara yardımcı olabilmek amacıyla, eřik deęerin kullanıldıęı akıllı telefon tabanlı bir sistem geliřtirmişlerdir. Fang ve ark. [38], Android tabanlı platform için düşme algılama prototipi oluřturmuşlar ve burada göğüs bel ve uyluk gibi farklı vücut bölgelerinden akıllı telefon verileri alınmıştır. Deney sonuçları, göğüs bölgesinin en iyi yer

olduğunu göstermiştir. Kau ve ark. [39] , ayırık Dalgacık Dönüşümü (DWT) algoritması kullanarak yine akıllı telefon ve ivme tabanlı bir çalışma yapmışlardır. Doğruluk % 92 olarak beyan edilmiştir.

2.1.2. Çevreye Yerleştirilen Sensörler


Çevreye yerleştirilen sensör sistemlerinde, kişi, herhangi bir sensör taşımak zorunda kalmaz. Ama buradaki kısıtlılık sensör yalnızca görüş açısı içerisindeki düşmelerin tespiti için kullanılabilir. Bu konuda birçok sensör kullanılmıştır. Bunlardan bazıları; kameralar, kızıl ötesi sensörler, basınç sensörleri, mikrofon ve zemin sensörleridir. Şekil 2.6’da çevreye yerleştirilen sensörlerin oda ortamında örnek bir resimsel gösterimi verilmiştir.



Şekil 2.6. Oda ortamındaki kişi takibi için kullanılan bazı sensör örnekleri

Çevreye yerleştirilen sensörlerle birçok çalışma yapılmıştır. Mesela, Li ve ark. [40], mikrofon dizisi kullanılarak akustik düşüş algılama sistemi geliştirilmiştir. Burada sesin kaynağı bulunur. Akustik algılayıcının performansı, benzetimi kurulan düşüş ve düşme sesleri kullanılarak değerlendirilmiştir. Hassaslık, % 100 ve özgünlük ise % 97 olarak beyan edilmiştir. Hassaslık değeri, doğru pozitiflerin sayısının, doğru pozitifler ile yanlış negatiflerin toplamına oranıdır. Özgünlük değeri ise doğru negatiflerin sayısının, doğru negatiflerin sayısı ile yanlış pozitiflerin sayılarının toplamına oranıdır. Rimminen ve ark. [41], yakın alan görüntülemesine dayalı bir zemin sensörü kullanarak düşme algılama yöntemi uygulamıştır. Khan ve ark. [12], yaşlı bir kişinin

normal aktivitelerinden toplanan akustik sinyalleri (ayak sesi sinyalleri) kullanarak düşmeleri, düşme olmayan aktiviteden ayırt etmede bir veri tanımlama modeli oluşturmak için bir denetimsiz düşme tespit sistemi sunmuşlardır. Şekil 2.7’de, sundukları sistemin blok diyagramı gösterilmiştir.




Şekil 2.7. Akustik (ayak sesi) sinyalleri kullanarak önerilen düşme algılama sisteminin blok diyagramı [12]

Kamera

Görsel sistemlerle kişi uzaktan izlenir ve hareketleri genellikle görüntü işleme yöntemleri ile analiz edilir. Ve böylece düşme olayının gerçekleşip gerçekleşmediği tespit edilir. Kamera-video tabanlı sistemler giyilebilir cihazlı sistemlere göre bazı avantajlara sahiptir. Bu avantajlardan biri, kişiye doğrudan müdahale etmediğinden (uzaktan izlediğinden) dolayı rahatsız edici değildir ve giyilebilir sensör gibi taşınmak zorunda değildir. Aynı zamanda ortamdaki titreşimlerden, akustik gibi gürültülerden, kolayca etkilenmezler.

Miguel ve arkadaşları [42] gömülü bir bilgisayar ve kamera içeren, duvarlara veya tavanlara monte edilebilir bir cihaz ile odayı izleyebilen bir sistem geliştirmişlerdir. Düşük maliyetli düşme detektörü sunmuşlardır. Detektörleri birçok algoritmayı, yüksek algılama doğruluğu ile makine öğrenme algoritmasına girdi olarak birleştirir. Düşme tespit edildiğinde bakıcıya resimle birlikte bir alarm mesajı gönderilir. 50'den fazla farklı düşme videosunda gerçekleştirilen testler %96'dan büyük bir tespit oranı göstermiştir. Şekil 2.8’de geliştirdikleri sistemin model diyagramı gösterilmektedir:



Şekil 2.8. Gömülü bir bilgisayar ve kamera içeren model diyagramı [42]

Cucchiara ve ark. [43], insanları tespit etmek ve izlemek ve tehlikeli davranışları tanımak için çok kameralı görüş sistemi önermiş. Burada x ve y eksenlerindeki silüetin şeklinin izdüşümü ile birlikte geometrik ve renkli özellikler de kullanılmış. Düşme şüphesi varsa, alınan bir alarmin geçerliliğini kontrol etmek için klinik tedavi uzmanlarına canlı video akışı sağlanır.

Kişi takibinde, CCD (Charge-Coupled Device) kameralar kullanılmıştır [44]. CCD kameralarla görüntü işlemek için bir bilgisayara ihtiyaç vardır. CCD kameralarda renkli görüntüler, özellikle ev ortamındaki kişilerin mahremiyeti konusunda problemlere neden olmaktadır. İzlenilen kişiler için izlenilme hissi, onların rahatça hareket edememelerine sebep olmaktadır. Kamera ile uzaktan, kişileri izlemek ve düşmelerini tespit etmek kolaydır ama düşük ışıklı ortamlarda ve gece karanlığında kişilerin tespiti zorlaşır [45]. Bu durum yanlış alarmların alınmasına neden olmaktadır. Renkli görüntü kameralarından derinliğin ölçülememesi, yüksek performansta düşme tespitinin yapılamamasına ve bu yüzden yanlış alarmların alınmasına neden olabilmektedir.

İçeriğe duyarlı sistemlerin en önemli problemlerinden biridir gizlilik. Bu probleme çözüm olması için birçok araştırmacı kızılötesi ışınlarla görüntüyü algılayan, RGB (Red Green Blue) kameralar gibi görüntüyü net göstermeyen kameralar kullanmışlardır. Son zamanlarda popüler olan ve kızılötesi ışın ile görüntü alan kameralara en güzel örnek, Microsoft' un geliştirdiği Kinect' tir.

Kinect

Kinect, Xbox 360 ve Xbox One video oyun konsolları ve Microsoft Windows bilgisayarlar için Microsoft tarafından üretilen hareket algılayıcı bir alettir.


Kinect özellikleri, aşağıdaki özellikleri desteklemektedir:

- Derinlik görüntüsü
- RGB görüntüsü
- Eğim
- Mikrofon Dizisi
- İskelet İzleme

Kinect, kızılötesi kullanır ve böylece camdan görülebilir. Kızılötesi kullandığı için Kinect doğrudan güneş ışığında çalışmayacaktır, örneğin açık havada.

Sadece Kinect ile elde edilen derinlik görüntülerine bakılarak bireylerin izlenimi sağlanabilir. Böylelikle kişinin mahremiyetini korumada, renkli kameralara göre daha avantajlı olmuş olur. Kişi ayrıntılı ve renkli bir görüntü ile izlenilmediğinden dolayı daha rahat hareket edebilir ve günlük aktivitelerini rahatça yapabilir. Aynı zamanda ucuz maliyetli Kinect aletinin kullanılması ekonomik olarak da daha uygun ve avantajlıdır.


Lei Yang ve arkadaşları [19] ise oda ortamında Kinect sensörünün kullanımı ile elde edilen üç boyutlu derinlik resimlerinden şekil analizi tabanlı kişi düşme tespiti metodu sunmaktalar. Derinlikli görüntülerdeki hareketli bireyin silueti, arka plan kareleri için bir çıkarma yöntemi ile elde edilmiş. Burada zemin düzlemi tahmin edilir ve hareketli bireyin şekil özellikleri analiz edilir. Pozisyon ve oryantasyon analizi yapıp (insan vücudunun merkezkaçları ve hedef ile zemin düzlemi arasındaki açı kriter olarak kullanılır) belirlenmiş bazı eşik değerlere göre düşmenin olup olmadığı tespit edilir. Şekil 2.9’da önerilen düşme algılama yönteminin akış şeması gösterilmektedir:



Şekil 2.9. Kinect kamera ile düşme tespiti yöntemi [19]

2.1.3. Giyilebilir ve Çevreye Yerleştirilen Sensör Sistemleri

Düşme olayını tespit etmede, çevreye yerleştirilen kamera veya Kinect gibi sensörler ile giyilebilir sensörlerin kullanıldığı sistemler geliştirilmiştir. Mesela, Bogdan Kwolek ve Michel Kepski [21], Kinect ve vücuda takılan ivmeölçer kullanılarak bulanık çıkarım temelli düşme tespiti yapmışlardır. Sistemlerinin grafiksel özeti Şekil 2.10’da verilmiştir:



Şekil 2.10. Kwolek ve Kepski’nin düşme tespitinde önerdikleri, Kinect ve ivmeölçer tabanlı model [21]

Düşme tespitinde uzaktan algılama, giyilebilir cihazlara göre daha kullanışlıdır. Kameralar bu konuda kullanılması tercih edilen aletlerdir. Fakat her kamera her ışık koşullarında etkili görüntü elde edemeyebilir ve bu yüzden düşmeler tespit edilemeyebilir. Son yıllarda gelişen kamera teknolojisinde, derinlik haritalarını sağlayan Kinect gibi aletlerin kullanımı ile zor aydınlatma koşullarında dahi daha etkili düşme tespitinin yapılması mümkün olmuştur.

2.2. Hareket Tanıma ve Düşme Tespitinde Kullanılan Teknikler

Hareket tanıma ve düşme tespitinde birçok teknik kullanılmıştır. Bu tekniklere, sinyal işleme teknikleri, makine öğrenmesi teknikleri ve derin öğrenme teknikleri örnek olarak verilebilir.


2.2.1. Sinyal İşleme

Hareket tespiti veya düşme tespiti yapabilmek için öncelikle sensörlerden veri sinyallerinin alınması ve toplanması gerekmektedir. Toplanan verilerden anlamlı bir sonuç elde edebilmek için o verileri işlememiz gerekmektedir. Hareket tespitinde çok çeşitli sinyal işleme yöntemleri kullanılabilir [46]. Bunlardan bazıları, verideki aykırı noktaların kaldırılması ve uygun ara değerlerin hesaplanması, uygun filtreleme yöntemlerinin kullanılması ile ön işleme (ortalama alma, standart sapma, kök kare ortalama, temel bileşen analizi, otomatik korelasyon, spektral tepe özellikleri, spektral güç özellikleri), bölümlendirme, uygun özellik çıkarımının yapılması ve veri indirgenmesidir. Özellik çıkarımı yapıldıktan sonra elde edilen büyük verilerin indirgenmesi, işlem hızını arttırmak ve işlem süresini azaltmak için önemlidir [47].

2.2.2. Hareket ve Düşme Tespitinde Çeşitli Makine Öğrenmesi Tabanlı Teknikler

Makine öğrenmesinin temelinde, çevreye adapte olan ve deneyimlerden öğrenen sistemlerin geliştirilmesi vardır. Makine öğrenmesi alanıyla bilgisayar bilimi, mühendislik, fizik, sinir bilimi, matematik gibi birçok alandan araştırmacılar ilgilenebilmektedir [24]. Geleneksel makine öğrenmesi teknikleri ham veriler ile sınırlı olduğundan bir özellik çıkarıcı tasarlamak için uzmanlık gerektirmektedir [25]. Makine öğrenmesi genellikle yapay zekâ ile ilgili görevleri yapan değişkenlerin kullanıldığı sistemlerdir. Bu görevlere tanıma, robot kontrolü, tahmin etme örnek olarak verilebilir.

Çeşitli makine öğrenmesi algoritmaları ve teknikleri insan aktivitesi tanımda kullanılmaktadır. Makine öğrenimi temelde denetimli, denetimsiz ve yarı denetimli olmak üzere üçe ayrılır. Denetimli öğrenmede verilen veri kümesindeki nesneler, bir özellik kümesi kullanılarak sınıflandırılırken denetimsiz öğrenmede ise incelenen nesneler için önceden tanımlanmış sınıf etiketleri yoktur [48]. Yarı denetimli makine öğrenmesinde veri kümesi, etiketli ve etiketsiz veri kümelerine ayrılmıştır [49]. Şekil 2.11’de makine öğrenmesi yöntemleri verilmiştir.



Şekil 2.11. Makine öğrenmesi çeşitleri

Denetimli Öğrenim

Bilgisayar, bir öğretici tarafından verilen örnek girdiler ve istenen çıktıları ile sunulur ve amaç, çıktıları girdileri eşleyen genel bir kural öğrenmektir. Özel durumlar gibi giriş sinyali sadece kısmen kullanılabilir veya özel geri bildirimle sınırlandırılabilir:

- Yarı gözetimli öğrenme: Bilgisayara sadece eksik bir eğitim sinyali verilir: Hedef çıktıların bir kısmı (çoğu kez) eksik olan bir eğitim kümesidir.
- Aktif öğrenme: bilgisayar, sınırlı bir örnek kümesi için yalnızca eğitim etiketleri alabilir ve ayrıca etiket almak için nesnelerin seçimini optimize etmelidir. Etkileşimli olarak kullanıldığında, bunlar etiketleme için kullanıcıya sunulabilir.
- Takviye öğrenimi: eğitim verileri (ödülleri ve cezalar şeklinde), yalnızca bir aracın sürülmesi veya bir rakibe karşı oyun oynama gibi dinamik bir ortamda programın eylemlerine geri bildirim olarak verilir.

Denetimli öğrenme tahmin metotları geliştirmek için sınıflandırma ve regresyon teknikleri kullanılır.

Sınıflandırma teknikleri farklı yanıtları tahmin eder. Örneğin bir organda kanserli dokunun olup olmadığını veya bir görüntü üzerinde değişiklik yapılmış mı yoksa o görüntü orijinal mi olduğu sınıflandırılabilir.

Sınıflandırma yapabilmek için Destek Vektör Makineleri, Diskriminant Analizi, Naif Bayes, En Yakın Komşu gibi algoritmalar kullanılır.


Regresyon ile sürekli tepkiler tahmin edilir. Mesela, sıcaklıktaki değişimler gibi. Tipik uygulama olarak elektrik yükü tahmini verilebilir. Çalışma bir veri aralığındaysa (mesela makine bozuluncaya kadar geçen sürede gibi) veya yanıtınızın niteliği gerçek bir sayıysa regresyon tekniği kullanılabilir.

Yaygın regresyon algoritmaları: Doğrusal Regresyon, kademeli regresyon, torbalanmış karar ağaçları, sinir ağları bunlara örnek verilebilir.

Denetimsiz Öğrenim


Öğrenme algoritmasına hiçbir etiket verilmez, girişinde yapı bulmak için kendi başına bırakılır. Denetlenmeyen öğrenme kendi içinde bir amaç (verilerde gizli kalıpları keşfetme) ya da sona doğru bir araç (özellikli öğrenme) olabilir.

Kümeleme, yaygın olarak kullanılan denetimsiz öğrenme tekniğidir. Araştırmalardaki veri analizinde, verilerdeki gizli kalıpları ve gruplamaları bulmak için kullanılır. Küme analizi, gen sırası analizi, nesne tanıma gibi uygulamalarda kullanılır. Şekil 2.12’te kümeleme ile verilerden gizli grupların veya kalıpların bulunmasının bir görsel gösterimi verilmiştir.




Şekil 2.12. Kümeleme ile verilerden gizli kalıpların bulunması

Kümeleme için yaygın olarak kullanılan algoritmalar, K - Ortalama, K – Medoids, Bulanık C – Ortalama, Gauss Karışımı, Nörolojik Ağlar, Gizli Markov Modeli gibi algoritmalarlardır. Şekil 2.13’te denetimli ve denetimsiz öğrenmeye ait bazı algoritmalar verilmiştir.



Şekil 2.13. Bazı Makine Öğrenmesi teknikleri

Destek Vektör Makineleri (DVM), desen sınıflandırma ve regresyon için kullanılan denetimli öğrenme modelidir. DVM’ deki amaç, görünmeyen test verilerindeki beklenen sınıflandırma hatasını en aza indiren en uygun aşırı düzlemi bulmaktır [50]. Şekil 2.14’de doğrusal bir destek vektör makinesi gösterimi vardır.




Şekil 2.14. Doğrusal Destek Vektör Makinesi gösterimi

Sınıflandırmada, deneysel riski (R_{emp}^{ε}) ve ağırlık vektörünün kare büyüklüğünü ($\|w^2\|$) en aza indirilmesi gereklidir. Bu yüzden, doğrusal regresyon aşırı düzlemi $[f(x, y) = w^T x + b]$, Denklem 2.1 minimize ederek yapılandırılmalıdır [51]. Regresyon aşırı düzlemindeki x , hiper düzlemin giriş verileridir. C , düzenleme parametresidir. C , kenar boşluğu genişliğini ve yanlış sınıflandırmayı değiştirir. $|y_i - f(x_i, w)|_{\varepsilon}$ fonksiyonu, epsilon duyarsız kayıp fonksiyonudur. Bu fonksiyon regresyon için kullanılan kayıp fonksiyonudur. Bu fonksiyon ε 'den büyükse $|y_i - f(x_i, w)| - \varepsilon$ olur, diğer durumlarda 0 olur.

$$R = \frac{1}{2} \|w^2\| + C \sum_{i=1}^l |y_i - f(x_i, w)|_{\varepsilon} \quad (2.1)$$

KNN, tanımlanmış bazı önceden belirlenmiş uzaklık ölçüsüne göre çıktıların öğrenme kümesindeki her noktada ve yığında en yakın komşularının tahmin edilmesidir. Sınıfı belli olmayan bir örnek geldiğinde en yakın verilerin bulunabilmesi için Öklid (Denklem 2.2), Manhattan (Denklem 2.3) ve Minkowski (Denklem 2.4) gibi uzaklık hesaplama ölçütleri kullanılmaktadır. Özellikler sayısal olduğunda, mesafe(d) sıklıkla Öklid mesafesi olarak tanımlanır. $x = \{x_1, x_2, \dots, x_n\}$ ve $y = \{y_1, y_2, \dots, y_n\}$ herhangi iki nokta olmak üzere mesafelerin formülleri aşağıdaki gibidir [52, 53]. Şekil 2.15'te en yakın komşu algoritması için örnek bir komşuluk gösterilmiştir.



Şekil 2.15. En yakın komşu gösterimi

Öklid Mesafesi:

$$d = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2.2)$$

Manhattan Mesafesi:


$$d = \sqrt{\sum_{i=1}^k |x_i - y_i|} \quad (2.3)$$

Minkowski Mesafesi:

$$d = \left(\sqrt[p]{\sum_{i=1}^k (|x_i - y_i|)^p} \right)^{1/p} \quad (2.4)$$

Optimum k değeri, N öğrenme boyutuna ve problem özelliklerine bağlıdır [53].

Karmaşık teknik sistemlerini analiz etmek için geliştirilen yaklaşımlardan biri de topluluk (ensemble) sınıflandırma tekniğidir. Bu yöntem, potansiyel sistem durumları için güvenilir sınıflandırma karar kuralları oluşturmada kullanılabilir. Topluluk öğrenme algoritmaları birden fazla sınıflandırıcı kullanarak tahminler yapmaya çalışır ve son aşamada bu sınıflandırıcılardan elde edilen değerler birleştirilip sonuçlar elde edilir [54]. Şekil 2.16’de topluluk sınıflandırma tekniği gösterilmiştir.




Şekil 2.16. Topluluk Sınıflandırma Tekniği

2.2.3. Derin Öğrenme

Derin öğrenme, makine öğrenmesi tekniklerinin bir alt kümesidir. Şekil 2.17’de Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme arasındaki kapsam ilişkisi gösterilmiştir. Derin öğrenmede her katman bir önceki katmanın çıktılarını işler ve özellik çıkarımı için birçok doğrusal olmayan bilgi işlem katmanını kullanır [55]. Şekil 2.18’de üç gizli katmanı olan bir derin öğrenme sinir ağı gösterilmiştir. Derin öğrenme, çok boyutlu veriler için oldukça verimlidir ve el yapımı veya el ile girilen özellikler yerine özellikler, otomatik olarak çıkarılır. Yüksek boyutlu verilerdeki karmaşık yapıların keşfedilmesinde oldukça başarılı sonuçlar vermektedir [25]. Derin çok katmanlı algılayıcılar, derin kıvrımlı sinir ağı ve yineleyen sinir ağı, bazı derin öğrenme yöntemleridir [56]. İnsan aktivite tanımda CNN (Convolutional Neural Network, Evrişimli Sinir Ağı), UKSB (Uzun Kısa Süreli Bellek) gibi farklı derin öğrenme teknikleri kullanılmıştır [57, 58].



Şekil 2.17. Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme arasındaki kapsam ilişkisi



Şekil 2.18. Üç gizli katmanı olan bir derin öğrenme sinir ağı

3. MATERYAL

Bu tez çalışmasında insan aktivitelerini tanıyıp tespit etmek ve düşme aktivitelerini düşme olmayan normal günlük aktivitelerden ayırt etmek için birçok materyal kullanılmıştır. Çalışmalarda kullanılan bilgisayar, Lenovo markasının Z50 modeli,- Intel Core i7 -4510U Core işlemcili, 8GB RAM belleğe sahip ve 64 bit işletim sistemi olan bir bilgisayardır. Çalışmalarda, iki farklı hazır veri kümesi çalışmalarda kullanılmıştır. Bunlar akıllı telefonun ivme ve jiroskop verilerinden elde edilen UCI HAR veri kümesi [1] ve Kepski ile Kwolek'in çalışmalarında kullandıkları ivme ve Kinect verilerini içeren veri kümesidir [2] .

UCI HAR veri kümesi: Otuz öznenin, bele monte edilen akıllı telefonun gömülü atalet sensöründen elde edilen günlük aktivite ivme verilerini içerir. Bu verilerin elde edilmesinde yaşları 19 ile 48 arasındaki 30 gönüllü rol oynamıştır. Her gönüllü, belinde bir akıllı telefon (Samsung Galaxy S II) taşıyarak altı aktivite (yürüme, merdivenden çıkma, merdivenden inme, oturma, ayakta durma, uzama) yapmışlardır. Gömülü ivmeölçer ve jiroskoptan 50 Hz açısal hız ile veriler toplanmıştır. Elde edilen verilerin %70'i eğitim, %30'u test verileri olarak seçilmiştir. İvmeölçer ve jiroskop sensor sinyalleri gürültü filtreleri uygulanarak ön işleme tabi tutulmuştur. Veriler 2.56 saniye ve %50 örtüşen (128 okuma/pencere) sabit genişlikte kayan pencerelerde örneklenmiştir.

Bu tez çalışmasında Kepski ve Kwolek'in çalışmalarında kullanmış oldukları, ivme ve Kinect kamera verileri de kullanılmıştır [2]. Bu veri kümesi 30'u düşme, 40'ı günlük aktiviteleri içermektedir. Düşme aktiviteleri iki Microsoft Kinect kamera ve ilişkili ivme verileri ile kaydedilmiştir. Günlük aktiviteler ise bir kamera ve ivmeölçer ile kaydedilmiştir. Sensör verisi 60 Hz de PS Move ve 256 Hz'li x-IMU aletleri ile toplanmıştır. Derinlik verileri PNG16 formatında kaydedilmiş ve milimetre cinsinden derinlik (d), yeniden ölçeklendirilmiştir. Derinlik formülü Denklem 3.1'de gösterilmektedir.

$$d = \frac{C_i \cdot P(x,y)}{65535} \quad (3.1)$$


Burada d harfi, milimetre cinsinden derinliği, C_i i'ninci kameranin ölçek oranını ve $P(x,y)$ ise PNG16 görüntüsünün (x,y) konumundaki piksel değerini belirtmektedir. Düşme dizisi: $C_0=6000$ ve $C_1=3640$ 'dır. Günlük aktiviteler: $C_0=7000$.

Bu hazır veri kümesi aynı zamanda zaman uyumlu (eş zamanlı) ivme verilerini de içermektedir. Görüntü çerçevesine karşılık gelen zaman uyumlu veriler; çerçeve numarasını, dizilimin başlamasından bu yana geçen milisaniye cinsindeki süreyi ve ara değerler ekli ivmeölçer verisini (SV_{total}) içermektedir. Ham ivme verileri ise dizilimin başlamasından itibaren süreyi ve ivme verilerini (SV_{total} , A_x , A_y , A_z) içermektedir.

Potansiyel düşme olarak belirlenen aktivitelerden daha doğru sonuçlar elde etmek için Kinect verilerinden elde edilen özellikli veri kümesi kullanıldı. Bu veri kümesinde bulunan özellikler:

- Etiket verileri (-1: kişi zemine uzanmış demek, 1: Kişi uzanmamış demek),
- Yükseklik genişlik oranı (görüntüde kişiyi sınırlayan sınır kutusunun en boy oranı),
- Büyük / küçük eksen oranı, sınırlayıcı kutunun kişinin pikselleri tarafından işgal edilme oranı,
- X eksen ve Z eksen (derinlik) için merkeze göre piksellerin standart sapması,
- Çerçeve içindeki insan yüksekliği ile ayakta durma anındaki insan yüksekliğinin (maksimum yükseklik) oranı,
- Gerçek yükseklik (milimetre cinsinden), kişi merkezinin zemine olan uzaklığı,
- P40 (40 cm yüksekliğinde bir küp şekline ait ve zemine yerleştirilmiş nokta bulutlarının sayısının, kişinin yüksekliğine eşit yükseklikteki küp şekline ait nokta bulutlarına oranı).

Veri kümelerinin dışında kullandığımız en temel materyal bilgisayar ve MATLAB uygulamasıdır. Matlab platformunun sınıflandırma öğrenici uygulaması, sinyal işleme aracı, görüntü işleme aracı gibi özel araçları da kullanıldı. Şekil 3.1’de sınıflandırma öğrenicinin MATLAB ara yüzü gösterilmektedir.



Şekil 3.1. Matlab Sınıflandırma Öğrenici (Classification Learner) arayüzü

4. METOT

Bu tez çalışmasında insan aktivitesini tanımak ve düşme tespiti yapmak için birçok teknik geliştirilmiştir. Bu teknikler, günlük normal aktivite hareketlerinin tespiti için kullanılan teknikler ve düşme eyleminin düşme olmayan eylemlerden ayırt edilmesi için kullanılan teknikler diye iki temel başlıkta verildi:


1. Hareket tanıma ve tespiti için kullanılan teknikler:

- Makine öğrenmesi teknikleri ve UKSB tabanlı derin öğrenme teknikleri ile kişi hareket tespiti yapılmıştır.
- Parçacık sürü optimizasyonu (PSO) yöntemi ile hareket tespiti yapılmıştır.

2. Düşme eylemini tespit etmek için kullanılan teknikler:

- Bir boyutlu yerel ikili desen özellik çıkarımı (1B-YİD) ve aşırı öğrenme makinesi (AMÖ) metotları ile düşme tespiti yapılmıştır.
- Kontrol grafiği tekniği kullanılarak ivme verilerinden potansiyel düşme eylemi tespit edilmiştir, daha sonra Kinect derinlik verilerinden elde edilen özellik verileri ile düşme doğrulanmıştır.

Şekil 4.1’de, tez çalışmasında kullanılan ve geliştirilen yöntemler gösterilmiştir.




Şekil 4.1. Hareket ve düşme tespiti için kullanılan metodlar

4.1. Hareket Tanıma için Önerilen Yöntemler


Tez çalışmasının bu adımında ivme verileri kullanılarak çeşitli makine öğrenmesi yöntemleri ile kişi hareket tespiti yapılmıştır. Daha sonra UKSB yöntemi ile hareket tespiti yapıldı ve her iki yöntemin sonuçları karşılaştırıldı.

4.1.1. Önerilen Makine Öğrenmesi Tabanlı Hareket Tespiti

Makine öğrenmesi yöntemi ile hareket tespiti senaryo adımları şöyledir: Öncelikle akıllı telefon ivme verileri alındı [1]. Veriler bilgisayara aktarılır, bilgisayarda MATLAB ortamında veriler derlenip eğitilir. Eğitilen veriler farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemlerinde kullanılır. Sınıflandırılmış eğitim verilerinden elde edilen eğitim modeli ile hareket tahminleri yapılır. Tahminler ile test verileri karşılaştırılıp hareket tanımadaki tahminlerin doğrulukları incelenir. Şekil 4.2 ve Şekil 4.3'te, tez çalışması yapılırken aktivite tanımda izlenen bazı adımlar gösterilmiştir.



Şekil 4.2. İvme verilerinin makine öğrenmesi yöntemleri ile test edilme aşamaları




Şekil 4.3. İvme verileri ile aktivite tanıma süreci

Özellik çıkarımı için ayrı ayrı üç eksenli ivme verileri; ortalama alma, standart sapma, kök kare ortalama, temel bileşen analizi, otomatik korelasyon, spektral tepe özellikleri, spektral güç özellikleri gibi ön işleme tabi tutulup 69 özellik elde edildi. Bu özelliklere eğitim aktiviteleri de eklenip eğitim verileri sınıflandırma algoritmaları ile sınıflandırıldı. . En iyi doğruluk veren sınıflandırıcı eğitim modeli olarak seçildi. Oluşturulan sınıflandırma modeli ve test verileri ile hareket tahminleri elde edildi. Tahmin edilen hareketler ile gerçek veriler karşılaştırılıp tahmin doğrulukları bulundu.

4.1.2. UKSB Tabanlı Derin Öğrenme Yöntemi ile Önerilen Hareket Tespiti Yöntemi

Bu çalışmada, UKSB ağı kullanılarak dizi verilerinin zaman adımlarındaki sınıflandırılması incelenmiştir. UKSB, bir tekrarlı sinir ağıdır. UKSB ağı, önemli olaylar arasında çok uzun gecikmeler olduğunda zaman serisini sınıflandırmada, işlemede ve tahmin etmede, deneyimden öğrenmek için uygundur [59]. UKSB mimarisi temelde üç bölümden oluşur. Bunlar, giriş kapısı, çıkış kapısı ve unutma kapısıdır. Şekil 4.4'te UKSB mimarisi gösterilmektedir.



Şekil 4.4. UKSB mimarisi

Şekilde 4.4’te X_t girdi vektörünü, H_{t-1} önceki hücre çıktısını, C_{t-1} önceki hücre hafızasını, H_t mevcut hücre çıktısını, C_t ise o anki hücre hafızasını ifade etmektedir. Denklem 4.1’de zaman serisi boyunca UKSB de işlenen fonksiyonların formülleri gösterilmektedir:

$$\begin{aligned}
 f_t &= \sigma (X_t * U_f + H_{t-1} * W_f) \\
 \bar{C}_t &= \tanh (X_t * U_c + H_{t-1} * W_c) \\
 I_t &= \sigma (X_t * U_i + H_{t-1} * W_i) \\
 O_t &= \sigma (X_t * U_o + H_{t-1} * W_o) \\
 C_t &= f_t * C_{t-1} + I_t * \bar{C}_t \\
 H_t &= O_t * \tanh(C_t)
 \end{aligned} \tag{4.1}$$

Formüllerdeki W ve U , bulundukları kapıların ağırlıklarını ifade etmektedir.

Burada test edilen veriler, vücuda giyilen bir akıllı telefonda elde edilen sensör verilerini içerir. Üç farklı yöndeki ivmeölçer okumaların standart sapması, ortalaması ve kök kare ortalaması alınarak özellik çıkarımı yapılmıştır ve dokuz özellik elde edilmiştir. Burada 200 farklı gizli katman tanımlanmıştır ve tam sıra çıkarılır. Ağda beş farklı sınıf tanımlandı (yürüme, durma, oturma, koşma ve dans etme). Tanımlanan ağ eğitildi ve eğitim sonucunda hareketler tahmin edildi.

4.1.3. İnsan Hareketlerinin Tanınması için Önerilen Parçacık Sürü Optimizasyonu Tabanlı Topluluk Sınıflandırıcı Yöntemi

1995 yılında Kennedy ve Eberhart tarafından sunulan Parçacık Sürü Optimizasyonu (PSO), sürekli doğrusal olmayan fonksiyonlar için bir yöntemdir [60, 61]. Yapay zekâdan, kuş sürüsünden, balık eğitiminden ve sürü teorisinden esinlenilmiştir. Sürü düzensiz gibi görünen bir koleksiyondur

(popülasyon). Sürüdeki her bir parçacık rastgele bir yönde hareket ediyor gibi gözüktüğüde kümelenme eğiliminde olan hareketli bireylerdir. Kennedy yiyecek arayan kuşlar için bir “mısır tarlası vektörü” geliştirmiştir.

Pozisyonlar ve vektörler öncelikle rastgele atanır, potansiyel çözümler aşırı uzayda uçurulur. Sonra her parçacık aşırı uzayda, en iyi (best) pozisyonunu takip eder. Burada bireysel en iyi konumu (pbest), popülasyona göre en iyi konumu (gbest) ve komşuluğa göre en iyi konumu (lbest) olmak üzere üç çeşit iyi konum vardır. Her zaman adımında rastgele bir şekilde kendi en iyisine doğru [pbest ve gbest (ya da lbest)] hızlanır. Parçacık Sürü Optimizasyonu adımları:

Adım 1: Aşırı uzaydaki popülasyonu tanımla.

Adım 2: Bireysel parçacıkların uygunluğunu ölç.

Adım 3: Hızları önceki en iyiye ve global en iyiye (ya da komşuluk en iyiye) göre değiştir.

Hız (v) ve konum (x), Denklem 4.2 ve Denklem 4.3’e göre güncellenir.

$$v_{id} = w_i \cdot v_{id} + c_1 \cdot \text{rand}() \cdot (p_{id} - x_{id}) + c_2 \cdot \text{rand}() \cdot (p_{gd} - x_{id}) \quad (4.2)$$

$$x_{id} = x_{id} + v_{id} \quad (4.3)$$

Burada v , parçacık hızını; x , parçacık konumunu; d , boyutu; c_1 ve c_2 pozitif sabit değerleri; $\text{rand}()$, rastgele fonksiyonları; p_{id} , i . parçacığın d boyutu için şu ana kadar ki en iyi pozisyonu, p_{gd} ise bütün popülasyon içinde mevcut olan global en iyi pozisyonu; w ise atalet ağırlığını temsil etmektedir. Bu formülün komşuluğa göre olan halinde p_{gd} yerine p_{ld} yazılabilir.

Adım 4: Şarta göre sonlandır.

Adım 5: 2. Adıma git

Global en iyi PSO algoritmasının temel adımları Şekil 4.5’te gösterilmektedir.

ADIM 1: N boyutlu S sürüsünü oluştur ve başlangıç değerlerini kontrol değişkenlerine ata

ADIM 2:

TEKRAR i:N (N: parçacık sayısı)

Kişisel en iyi pozisyonu belirle (pbest)

EĞER (pbest_i < pbest_{i+1})

pbest_i = pbest_{i+1} %Kişisel en iyi

gbest_i = max(pbest) %Global en iyi

TEKRAR (1: mesafe)

$v_{id} = w_i \cdot v_{id} + c_1 \cdot \text{rand}().(p_{id} - x_{id}) + c_2 \cdot \text{rand}().(p_{gd} - x_{id})$


$x_{id} = x_{id} + v_{id}$

TEKRAR SON

TEKRAR SON

ADIM 3: Sonlandırma kriterine kadar devam et

Şekil 4.5. Parçacık sürü optimizasyonu algoritması




Şekil 4.6. Tek parçacık için hız ve konum güncellemelerinin iki boyutlu, geometrik gösterimi

Şekil 4.6'da parçacığın t zaman adımındaki ve (t+1) zaman adımındaki durumları gösterilmiştir [62]. Şekilde x_t , t zaman anındaki pozisyonunu temsil etmektedir. Yeni pozisyon olan $x_{(t+1)}$, küresel en iyi pozisyon olan $gx_{(t+1)}$ 'e yaklaşmıştır. $gx_{(t+1)}$, sürü tarafından bulunan en iyi pozisyonudur. px_t ise parçacık tarafından başlangıçtan beri erişilmiş en iyi pozisyonudur. Bir sonraki zaman adımında kişisel en iyi pozisyon Denklem 4.4'deki gibi hesaplanır.


$$px_{(t+1)} = \begin{cases} px_t, & f(x_{(t+1)}) \geq f(px_t) \\ x_{(t+1)}, & f(x_{(t+1)}) < f(px_t) \end{cases} \quad (4.4)$$

Büyük veri kümeleri üzerinde tek bir sınıflandırıcı ile yüksek başarımın elde edilmesi çoğu zaman zordur. Birden fazla sınıflandırıcının uygun şekilde birleştirilmesi ile daha yüksek başarımlar elde edilebilir. Bu çalışma kapsamında önerilen topluluk seçim yöntemi parçacık sürü optimizasyonu tabanlı bir topluluk kullanarak bir araya getirilmekte ve sınıflandırma performansını en fazla arttıran en iyi sınıflandırıcı grup otomatik olarak seçilmektedir. Önerilen yöntemin blok şeması Şekil 4.7’de verilmiştir.



Şekil 4.7. Parçacık sürü optimizasyonu tabanlı topluluk sınıflandırıcı

Şekil 4.7’de ilk olarak üç eksenli ivme verileri alınarak özellik çıkarımı yapılmaktadır. Özellik çıkarımında 66 adet özellik çıkarılmaktadır. Çıkarılan özellikler her bir ivme eksenin ortalaması, karelerin ortalaması, oto korelasyon özellikleri, frekans spektrumunda tepe değerleri ve pozisyonları olarak belirlenmiştir. Özellik çıkarımında iki farklı hareket için frekans spektrumunda tepe değerleri Şekil 4.8’de verilmiştir. Şekil 4.7’deki DVMC, Kübik Destek Vektör Makinelerini; KA, Karar Ağacını; KEYK, K-En Yakın Komşu sınıflandırıcısı; DAS, Doğrusal ayırt edici sınıflandırmayı ve DVMG, Gauss Destek Vektör Makinalarını temsil etmektedir.



Şekil 4.8. Yürüme ve merdiven çıkma hareketleri için frekans spektrumları

Şekil 4.8’den de görüldüğü gibi yürüme ve merdiven çıkma hareketlerinde hem genlikler hem de oluşan tepe değerlerinin pozisyonları farklıdır. Dolayısıyla iki bilgi de özellik çıkarımında kullanılmaktadır. Özellik çıkarımından sonra elde edilen eğitim kümesi her bir sınıflandırıcıya verilerek eğitilmiş modeller elde edilmektedir. Bu modellerin seçimi için MATLAB sınıflandırma öğrenici aracı kullanılmıştır. Bu araç aynı veri için çoklu sınıflandırma yöntemlerini kullanarak verileri eğitmektedir. Eğitimde çapraz doğrulama kullanılmakta olup önerilen sınıflandırıcıların performansı eğitimde kullanılmayan veriler ile ölçülmektedir. Bu araç kullanılarak ilgili eğitim kümesi farklı sınıflandırıcılar ile sınıflandırma performansları ölçülmüş ve bunlar içerisinde Kübik Destek Vektör Makineler (KDVM), Karar Ağacı (KA), K-En Yakın Komşu sınıflandırıcı (KEYK), Doğrusal ayırt edici sınıflandırma ve Gauss Destek Vektör Makinalar (GDVM) en yüksek performansı veren sınıflandırıcılar olduğu için seçilmiştir.

Parçacık sürü optimizasyonun orijinal versiyonu reel sayılar üzerinde çalışarak reel uzayda işlem yapar. Hem hız hem de pozisyon güncellemesi reel sayılar üzerinde verilen aralıkta yapılır. Burada önerilen yöntem farklı sınıflandırıcılar içerisinde hangi kombinasyondan sınıflandırıcı seçilirse daha iyi bir sınıflandırma performansı elde edileceğidir. Bu yüzden ayrık parçacık sürü optimizasyonu önerilmiştir. Ayrık parçacık sürü optimizasyonundan her parçacık Denklem 4.5’deki gibi kodlanmaktadır.

$$X(i) = (x_{i,1}, x_{i,2}, \dots, x_{i,n}) \quad (4.5)$$

Denklemden $x_{i,j}$ 0 ile 1 değerlerinden birini alır. Parçacık sayısı $i=1, 2, \dots, N$ ile gösterilmektedir. Her parçacığın uzunluğu (n) topluluk sınıflandırıcı sayısıdır. Bir parçacığın her bir biti bir sınıflandırıcıya karşılık gelir ve eğer 1 ise topluluk sınıflandırıcıda etkisinin olacağı ve 0 ise herhangi bir etkisinin olmayacağını ifade eder. Elimizde 6 sınıflandırıcı ve 3 parçacık olduğu varsayılırsa kodlama Tablo 4.1’deki gibi gösterilebilir.

Tablo 4.1. Altı sınıflandırıcı için üç parçacıklı parçacık sürü optimizasyon kodlaması

Sınıflandırıcı Parçacık	S1	S2	S3	S4	S5	S6
X(1)	1	0	1	0	1	1
X(2)	0	1	1	1	0	0
X(3)	1	0	0	0	1	1

Tablo 4.1’de X(1) parçacığında S1, S3, S5 ve S6 sınıflandırıcıları topluluk sınıflandırma için ağırlıklı oylamada olacaktır. Çünkü kodlamada sadece bu sınıflandırıcılar 1 değerini almıştır. Başlangıçta parçacıkların pozisyonları Denklem 4.6’daki gibi elde edilmektedir.

$$x_{i,j} = \begin{cases} 1, & \text{Eger } r \geq 0.5 \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (4.6)$$

Denklem (4.5)’de r $[0,1)$ aralığında rastgele olarak üretilmiş tek düze bir reel sayıdır. Her pozisyon vektörü bir hız vektörü ile ilişkili olup bu vektör $V(i) = (v_{i,1}, v_{i,2}, \dots, v_{i,n})$ ile verilmektedir. X(i) parçacığındaki her bir $x_{i,j}$ boyutu $V(i)$ ’deki $v_{i,j}$ vektörüne bağlı olarak değişir. Popülasyonda i. parçacığın hızı olan $V(i)$ ’nin her boyutu $v_{i,d}$ Denklem 4.7’e göre güncellenir.

$$v_{i,d} = \psi * v_{i,j} + r_1 (pb_{i,j} - x_{i,j}) + r_2 (gb_j - x_{i,j}) \quad (4.7)$$

Denklemde ψ ($0 < \psi < 1$) atalet momentini, r_1 bilişsel ölçekleme ve r_2 sosyal ölçekleme parametresini göstermektedir. Denklemde $pb_{i,j}$ i. parçacığın j boyutu için şu ana kadar ki en iyi pozisyonu, gb_j ise bütün popülasyon içinde j. Boyut için global en iyiyi gösterir. Hız güncellemesi yapıldıktan normalde sürekli uzayda çalışan parçacık sürü optimizasyonunda hız ve önceki konum toplanarak yeni pozisyon bulunmaktaydı. Fakat ayrık zamanlı parçacık sürü optimizasyonunda bu işlem Denklem 4.8’deki gibi yapılmaktadır.

$$x_{i,j} = \begin{cases} 1, & \text{Eger } r \geq \xi(v_{i,j}) \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (4.8)$$

Denklem 4.7’de r , $[0,1)$ aralığında üretilen rastgele bir sayıyı gösterirken $\xi(v_{i,j})$ ise Denklem 4.9’a göre hesaplanır.

$$\xi(v_{i,j}) = \frac{1}{1 + \exp(-v_{i,j})} \quad (4.9)$$

Denklem 4.9’da hız pozitif ve büyük değer olursa hesaplanan değer 1’e yakın çıktığından ilgili bitin bir olma olasılığı yükselir. Eğer hız negatif ve büyük bir değer ise hesaplanan ifade 0’a çok yakın olduğu için parçacığın ilgili pozisyonundaki bitin sıfır olma olasılığı yükselir.

Parçacık sürü optimizasyonun amaç fonksiyonu ise her bir birey için seçilen sınıflandırıcılar ile çoğunluklu oylamaya göre doğru sınıflandırılan örnek sayısının toplam örnek sayısına bölümüdür. Bu aynı zamanda topluluk sınıflandırıcısının doğruluk oranı olarak da söylenebilir. Uygulama zaman aralığı değiştiğinde tek bir öğrenme algoritması kullanmak kabul edilebilir bir performans sunmayabilir. Herhangi bir sınıflandırıcı bir m zaman aralığında iyi sonuç verirken farklı bir zaman aralığında iyi sonuç vermeyebilir. Topluluk sınıflandırıcıda, birkaç sınıflandırıcı birlikte son çıkışı oluşturur. Topluluk sınıflandırıcıda, birkaç sınıflandırıcı birlikte son çıkışı oluşturur. Önerilen parçacık sürü optimizasyonu tabanlı yöntem çoğunluk oylamaya göre bir test örneğinin sınıfını belirler. İki sınıflı bir problem için 5 sınıflandırıcının çoğunluk oylamaya göre çıkışı Tablo 4.2’de verilmiştir.

Tablo 4.2. Çoğunluk oylama ile sınıflandırma

Örnek No	S1	S2	S3	S4	S5	Sınıf Etiketi
1	1	1	2	2	1	1
2	1	1	1	2	1	1
3	2	2	1	2	2	2
4	1	2	1	1	1	1


Tablo 4.2’de birinci örnek için S1, S2 ve S5 sınıflandırıcıları 1 değerini verdiği için sonuç 1 olarak verilmiştir. Diğer örnekler de benzer şekilde sonuç vermektedir.

4.2. Düşme Eylemlerinin Tespiti için Önerilen Teknikler

Bu tez çalışmasında öncelikle ivme verileri kullanılarak Bir Boyutlu Yerel İkili Desen (1B-YİD) yöntemiyle özellik çıkarımının yapıldığı ve Aşırı Öğrenme Makinesi (AÖM) yönteminin kullanıldığı düşme tespiti yöntemi geliştirilmiştir. Başka bir teknik olarak kontrol grafiği kullanıldı ve kontrol grafiğinden elde edilen potansiyel düşme bilgisini doğrulamak için de Kinect derinlik görüntülerinin özellik verileri kullanılmıştır. Aşağıdaki alt başlıklarda bu iki yöntem detaylı bir şekilde anlatılmıştır.

4.2.1. Bir Boyutlu Yerel İkili Desen ve Aşırı Öğrenme Makinesi Yöntemleri ile Düşme Tespiti

Bu çalışmada, düşen bireylere hızlı ve etkili yardım sağlamak amacıyla düşme eylemini doğru, hızlı ve verimli bir şekilde algılayan bir sistem geliştirmeyi amaçlanmıştır. Bu amaçla, tek boyutlu Yerel İkili Desen (1B-YİD) ve Aşırı Öğrenme Makinesi (AÖM) yöntemlerini kullanarak normal aktiviteler ile düşme aktivitelerini birbirinden ayıran bir sistem önerilmiştir. Burada Öncelikle üç eksenli ivme sensöründen elde edilen verilerin büyüklükleri ön işleme adımında hesaplanıyor. 1B-YİD yöntemini kullanarak özellik çıkarımı yapıyor, daha sonra Aşırı Öğrenme Makinesi yöntemiyle özellik çıkarma işleminden elde edilen veriler eğitildi. Eğitim sonucunda düşme doğrulukları incelenmiştir. Şekil 4.9’da düşme eylemini bulmak için önerilen 1B-YİD ve AMÖ metodlarının iş akışı gösterilmektedir.




Şekil 4.9. Düşme olayını bulmak için önerilen 1B-YİD ve AMÖ metodlarının iş akışı

1-B-YİD Özellik Çıkarımı

Yerel ikili desen bir doku tanımlayıcıdır [63]. Yerel ikili desen, gri ölçekli bir sabit niceliklidir [64]. Görüntü işleme uygulamalarında verimlidir [65]. Ojala ve arkadaşları [64], Wang ve He'nin 3x3 piksel komşuluğundan elde edilen sekiz elemandan oluşan ve her biri 0, 1 ve 2 değerlerinden biri olan sözde doku birimi tabanlı sundukları doku analizi metodunun iki seviyeli versiyonunu sunmuşlardır. Wang ve He [74]'nin sundukları 3x3 komşuluk metodunda uzaysal üç seviyeli desenleri tanımlayan $3^8 = 6561$ olası doku birimi bulunurken Ojala ve arkadaşlarının sundukları iki seviyeli versiyonda $2^8 = 256$ olası doku birimi vardır. İkili durumda, 3x3 boyutundaki doku birimlerinde merkezdeki değer, komşuları için bir eşik değeri durumundadır. Aşağıdaki örnekte de görüldüğü gibi sol üst köşeden başlayarak komşu değerler merkezdeki eşik değeri ile kıyaslanır. Eğer komşu değer eşik değerden küçük ise o konumdaki değer 0 olur, eğer büyükse 1 olur. Ve sonuç olarak tüm değerler ikilik tabanda yan yana getirilir ve bu sayının onluk taban sonucu

hesaplanır. Bulunan sonuç merkezdeki sayının yeni değeri olmuş olur. Şekil 4.10’da $x = \{58, 64, 2, 93, 78, 7, 3, 125\}$ değerlerine sahip örnek bir veri penceresinin 2B-YİD yöntemi ile çözümü gösterilmektedir.



Şekil 4.10. 2B-YİD kodunun hesaplanması

$$P_c = \sum_{k=1}^n f(k)2^{n-1} \quad (4.10)$$

$$f(k) = \begin{cases} 1 & , P_k \geq P_c \\ 0 & , P_k < P_c \end{cases} \quad (4.11)$$


Burada 3x3 piksel komşuluğunda $n=8$ 'dir. Yukarıdaki Denklem 4.10 ve Denklem 4.11'da P_c , merkezdeki pikselin gri seviye değerini, P_k ise merkezi çevreleyen pikselin değerini temsil etmektedir.

Aşırı Öğrenme Makinesi

Hang ve arkadaşları [66, 67], yaptıkları çalışmalar sonucunda öğrenmeyi son derece hızlı hale getiren ve iyi genelleme performansı üreten, en küçük eğitim hatasına ulaşmanın yanında en küçük ağırlık normuna da ulaşma eğiliminde olan Aşırı Öğrenme Makinesini (AÖM) sunmuşlardır. AÖM, rastgele düğümleri seçen ve analitik olarak ağırlık çıktığı ağırlıklarını belirleyen tek gizli katman


ileri beslemeli sinir ağıdır. AÖM, ileri besleme sinir ağları için iyi bir genelleme performansına sahiptir.

Öncelikle sinir ağından bahsetmek gerekirse sinir ağında, insan beyninin sinir hücrelerinden, ara bağlantılarından ve etkileşimlerinden esinlenilmiştir [68]. Sinir ağlarında birçok işlem elemanları bulunur. Giriş katmanında ağa verilmek istenen giriş dizisi verilir. İlk katman olan bu giriş katmanındaki her bir işlem elemanı, girdi dizisinin bir bileşenini alır ve devretme fonksiyonuna göre bunu işler. İşleme sonucunda elde edilen basit çıktı bir sonraki katmandaki işleme elemanlarına aktarılır. Bu işlemlerin sonucu bir çıktı dizisidir. Girdiler ve uyarlanabilir katsayılar (ağırlıklar) zamanla değişebilir, ağ adapte olur ve öğrenir [68]. Kullanılan AÖM ağı kabaca Şekil 4.11’de gösterilmektedir.



Şekil 4.11. Nöronlar ile basit bir tek gizli katmanlı yapay sinir ağı

Yapay sinir ağları, düğüm veya yapay nöron olarak adlandırılan, birçok uyarlanabilir basit işleme elemanlarının birbirine bağlanmasıyla oluşur, bu elemanlar, veri işleme ve bilgi sunumu için toplu olarak paralel hesaplamalar yapabilirler [69]. Burada birbirine bağlı nöronların ağırlıkları, Biyolojik nöronların sinapsları olarak düşünülebilir [70]. Yapay sinir ağlarındaki temel yapı, insan beyni taklit edilerek yapay sinir ağlarının öğrenmesini sağlayacak algoritmaların geliştirilmesidir [69]. Şekil 4.12’de yapay sinir ağının matematiksel gösterimi gösterilmektedir.



Şekil 4.12. Yapay Sinir Ağı'nın Matematiksel Gösterimi

$$y = \sum_{i=1}^t (x_i w_i) + b \quad T \quad (4.12)$$

Denklem 4.12'deki $x_1, x_2 \dots$ girdi verilerini, b bias sabitini, f aktarma fonksiyonunu, $w_1, w_2, \dots$ ise nöronlar arasındaki bağlanma ağırlıklarını temsil etmektedir. y de yapay sinir ağının çıktısını belirtmektedir.

AÖM'nin algoritması ise aşağıda anlatılmaktadır:

$\mathfrak{N} = \{ (x_i, t_i) \mid x_i \in \mathbb{R}^n, t_i \in \mathbb{R}^m, i=1, \dots, N \}$ eğitim kümesi verilmiş olsun, aktivasyon fonksiyonu $g(x)$ ve gizli düğüm sayısı $\tilde{N}$ olsun

Adım 1: Rastgele giriş ağı w_i atayın ve bias b_i atayın.

$i = 1, 2, \dots, \tilde{N}$ olsun

Adım 2: Gizli katman çıktı matrisini (H) Denklem 4.13'e göre hesaplayın

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_{\tilde{N}}) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_{\tilde{N}} + b_1) & \dots & g(w_{\tilde{N}} \cdot x_{\tilde{N}} + b_{\tilde{N}}) \end{bmatrix}_{\{\tilde{N} \times \tilde{N}\}} \quad (4.13)$$

Adım 3: Çıkış ağırlığını Denklem 4.14 ve Denklem 4.15'e göre hesaplayın β

$$\beta = H^+ T \quad (4.14)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\{\tilde{N} \times m\}}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{\{N \times m\}} \quad (4.15)$$

4.2.2. Düşme Tespiti için Önerilen Kontrol Grafiği Yöntemi

Kontrol grafiği, numune veya zamana karşı bir numuneden ölçülen kalite karakteristiğinin grafiksel olarak bir gösterimidir ve olağandışı değişkenlik kaynakları oluştuğunda örnek ortalamaları, kontrol limitinin dışında bir şekilde grafikte çizilir [71]. Kontrol limitleri üst kontrol limit (ÜKL) ve alt kontrol limit (AKL).

$\bar{x}$ grafiği için kontrol limitleri belirleme adımları:

Adım 1: Kalite karakteristiği bilinen ortalama (μ) ve standart sapma (σ) ile dağıtıldığını varsayalım. $x_1, x_2, x_3, \dots, x_n$, n boyutunda bir örnek istatistik ise, bu örneklerin ortalaması Denklem 4.16 ile bulunur:

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} \quad (4.16)$$

Adım 2: $\bar{x}$ 'nin ortalamasını $\mu_{\bar{x}}$ ve $\bar{x}$ 'nin standart sapmasını $\sigma_{\bar{x}}$ olarak kabul edilirse, üst kontrol limit Denklem 4.17'yle, merkez çizgisi Denklem 4.18'yle ve alt kontrol çizgisi Denklem 4.19 ile bulunur.

$$\text{Üst Kontrol Limit} = \mu_{\bar{x}} + L\sigma_{\bar{x}} \quad (4.17)$$

$$\text{Merkez Çizgisi} = \mu_{\bar{x}} \quad (4.18)$$

$$\text{Alt Kontrol Limit} = \mu_{\bar{x}} - L\sigma_{\bar{x}} \quad (4.19)$$

Burada L, standart sapma birimlerinde ifade edilen kontrol sınıflarının merkez hattına olan uzaklığıdır. Kontrol grafiğinin geliştiricisi, Walter A. Shewhart'dir (1920) [71]. Bu yüzden bu kurallara göre geliştirilen kontrol grafiklerine, Shewhart kontrol grafiği adı verilir.

Aralık grafiği (R) için limitlerin belirlenme adımları:

Adım 1: $x_1, x_2, x_3, \dots, x_n$, n boyutlu bir örnek ise, bu örneklerin aralığı en geniş ve en küçük gözlemlerin arasındadır. Denklem 4.20'da gösterildiği gibi:

$$R = x_{\max} - x_{\min} \quad (4.20)$$

Adım 2: m tane örneğin aralık değerlerini $R_1, R_2, R_3, \dots, R_m$ olarak kabul edersek ortalama aralık Denklem 4.21'deki gibidir:

$$\bar{R} = \frac{R_1 + R_2 + R_3 + \dots + R_m}{m} \quad (4.21)$$

Adım 3: R grafiği için kontrol sınırları Denklem 4.22, 4.23 ve 4.24'e göre bulunur.


$$\text{Üst Kontrol Limit} = D_1 \bar{R} \quad (4.22)$$

$$\text{Merkez Çizgisi} = \bar{R} \quad (4.23)$$

$$\text{Alt Kontrol Limit} = D_2 \bar{R} \quad (4.24)$$

Burada D_1 ve D_2 kontrol sınırı için sabit faktörlerdir.

Kontrol grafiği zamanla olan işlemleri hesaplar, kontrol limitleri ile işlemin kontrol altında olup olmadığını gösterir. Kontrol grafiği istenmeyen değişiklikleri, üst ve alt kontrol sınırlarını geçen aykırı noktaları gösterebilmektedir. Şekil 4.13'te şekilde örnek bir kontrol grafiği sonucu gösterilmektedir. Kontrol grafiğinde de gösterildiği gibi üst ve alt sınır noktalarını geçen uç noktalar kırmızı yuvarlak işaret ile belirtilip, bu noktaların aykırı noktalar olduğu gösterilmektedir.




Şekil 4.13. Aykırı noktaları gösteren örnek kontrol grafiği

Bu çalışmada, kontrol grafiğini kullanarak düşme olayının daha etkili tespit edilebileceği düşünülmüştür. Bu yüzden Matlab’ın özel fonksiyonu olan “*controlchart*” fonksiyonu kullanılarak aktivitelerdeki düşmenin olabileceği potansiyel düşme anları, ivme verilerinden tespit edilmiştir. Çalışmada, deneyler yapılırken daha çok R kontrol grafiği kullanılmıştır.

Kontrol grafiği, numune veya zamana karşı bir numuneden ölçülen kalite karakteristiğinin grafiksel olarak bir gösterimidir ve olağandışı değişkenlik kaynakları oluştuğunda örnek ortalamaları, kontrol limitinin dışında bir şekilde grafikte çizilir [71]. Kontrol limitleri üst kontrol limit (ÜKL) ve alt kontrol (AKL) limitlerdir. Eğer işlem kontrol altındaysa, örneklerin (numunelerin) nerdeyse tamamı kontrol çizgilerinin arasında kalacak şekilde kontrol limitleri seçilir. Numune noktaları kontrol limitlerinin arasında ise işlem kontrol altındadır denilebilir. Eğer kontrol limitini aşarsa kontrolsüzlüğün oluştuğunu belirtir. Böylelikle zaman içerisindeki işlem örneklerinden hangilerinin aykırı noktalar olduğu tespit edilir. Düşme eylemini de günlük aktivitelerden farklı olarak belli bir süre hareket eden bireyin aniden ve hızlı bir şekilde yere uzanması olarak tanımlarsak ani gerçekleşen eylemler kontrol grafiğinde aykırı noktalar olarak belirlenecektir. Aynı zamanda üst ve alt kontrol limitleri, belirlenen kontrol kuralları ile değiştirilebilir ve düşme eylemlerini bulmada etkili olan bu limitlerin hassasiyeti uygun olan kontrol kuralının seçilmesi ile oldukça kolay bir şekilde düşme eylemi tespit edilebilir. Bu yüzden ayakta iken eğilip yerden bir şey alma veya günlük bir aktivite olarak, normal bir şekilde yere uzanma gibi günlük aktiviteler ile ani gerçekleşen düşme aktivitelerini birbirinden ayırt etmek kolaylaşmaktadır.


Otuz öznenin, bele monte edilen akıllı telefonun gömülü atalet sensöründen elde edilen günlük aktivite ivme verilerini içeren UCI HAR veri kümesi kullanılmıştır [72]. Düşme aktivitelerinde çoğunlukla belirgin olan aykırı noktaların yürüme, oturma, merdivenden çıkma ve inme, ayakta durma, uzanma gibi günlük aktivitelerde çok nadir olduğu, hatta bazı büyük aktivitelerde hiç olmadığı gözlemlenmiştir. Şekil 4.14’te gösterilen aktiviteler, UCI HAR veri

kümesinden elde edilen çok büyük günlük normal aktivite verileridir. Şekillerde de görüldüğü gibi yürüme, oturma, durma gibi günlük aktiviteler ne kadar uzun süre gerçekleşmiş olsa bile kontrol grafiğinin üst ve alt sınırlarını geçmemektedir.



Şekil 4.14. Çok büyük boyuttaki bazı günlük normal aktivite verilerinin R kontrol grafiği sonuçları

Aktivite veri dizisinde düşmenin olduğu anların indeksini bulmamıza yardımcı olan kontrol kuralı (controlrule) fonksiyonu ile de ilgili potansiyel düşme anları tespit edildi. Bu tez çalışmasında, ivme verileri [2] kullanılarak kontrol grafiği ve kontrol kuralı ile tespit edilen potansiyel düşme eylemlerinin doğruluğundan emin olmak için kontrol kuralı fonksiyonundan elde edilen potansiyel düşme anları belirlenip bu anlar ile ilgili Kinect özellik verileri incelendi. İvme verisi ile belirlenen potansiyel düşme anındaki Kinect özellik verisine gidilir. O özellik verisinde de aktivite etiketi de düşmenin olduğunu belirtiliyorsa düşme olayı doğrulanmış olmaktadır. Bu çalışmada sunulan düşme tespiti işlemlerinin genel bir taslağı Şekil 4.15'te verilmektedir.




Şekil 4.15. Düşme tespiti işlemlerinin genel taslağı

Şekil 4.15’de bu tez çalışmasında, kontrol grafiği ile düşme tespitinin yapılması aşamaları gösterilmektedir. Öncelikle üç eksenli ivme verileri alınır. Bu veriler kontrol grafiğine girdi olarak verilir. Belirlenen kural (Western Elektrik kurallarından biri; we1, we2, we3 gibi) ile aykırı noktalar bulunur. Kontrol kuralları fonksiyonu ile aykırı noktaların bulunduğu veri indeksleri tespit edilir. Tespit edilen bu aykırı noktalar, potansiyel düşme anları olarak kabul edilir. Bu anlar ile ilgili Kinect özellik verilerine gidilip düşmenin olup olmadığı (doğruluğu) kontrol edilir. Elbette kullanılan Kinect özellik verisinde birçok özellik bulunmaktadır. Bu veri kümesinde bulunan özellikler:


- Etiket verileri (-1: kişi zemine uzanmış demek, 1: Kişi uzanmamış demek),
- H (Kişinin gerçek yüksekliği, mm)
- Yükseklik genişlik oranı (görüntüde kişiyi sınırlayan sınır kutusunun en boy oranı),
- Büyük / küçük eksen oranı (sınırlayıcı kutunun yükseklik ve genişlik oranı),
- Sınırlayıcı kutu işgali (sınırlayıcı kutunun kişinin pikselleri tarafından işgal edilme oranı)
- X ekseni ve Z ekseni (derinlik) için merkeze göre piksellerin standart sapması,
- Çerçeveedeki insan yüksekliği ile ayakta durma anındaki insan yüksekliğinin (maksimum yükseklik) oranı,
- Gerçek yükseklik kişinin merkezinin zemine uzaklığı, mm cinsinden),
- P40 (40 cm yüksekliğinde bir küp şekline ait ve zemine yerleştirilmiş nokta bulutlarının sayısının, kişinin yüksekliğine eşit yükseklikteki küp şekline ait nokta bulutlarına oranı).

Şekil 4.16’de bir kişinin hareketi esnasında elde edilmiş olan, arka planı çıkarılmış derinlik görüntüsünde kişiyi sınırlayan sınır kutusunun örnek resimleri gösterilmiştir.



Şekil 4.16. Arkaplan çıkarımı yapılmış ikili resim ve tespit edilen kişiyi sınırlayan kutunun gösterimi


Kinect özellik veri kümesinin çıkarılması için öncelikle Kinect derinlik görüntülerinden kişi tespiti yapılmalı. Böylelikle çıkarılan kişinin en boy oranı, çerçevedeki insan yüksekliği, ayakta durma anındaki insan yüksekliği gibi özellikler elde edilebilir. Derinlik görüntülerinden kişinin elde edilebilmesi için görüntülerdeki arka plan çıkarılmalıdır. Bu çalışmada kullanılan verilerde [2] kişi çıkarımı yapılması için derinlik referans görüntüleri kullanılmıştır. Derinlik referans görüntülerini elde etmek için her piksel, geçmiş birkaç görüntünün piksel değerlerinin ortancası alınarak bulunur. Derinlik referans görüntüsü en eski piksellerin kaldırılıp sıralanan referans görüntülerindeki piksellerle güncellenmesi ve sonra ortanca değerinin çıkarılması ile güncelleniyor. Ön plandaki nesneleri elde etmede referans görüntüsü kullanılmaktadır.



Şekil 4.17. Sandalyeden düşme eyleminin zamana göre ikili resme (en üstteki), derinlik görüntüsüne (ortadaki) ve renkli görüntüye (en alttaki) göre gösterimi


Şekil 4.17’de, ortadaki derinlik görüntülerinden kişi çıkarımı sonucu elde ettiğimiz ikili resimler (binary images) ile ilgili hazır veri renkli görüntüleri ve derinlik görüntüleri, zaman akışına uygun bir şekilde gösterilmektedir.

Potansiyel düşme anlarındaki Kinect özellik verileri, aynı zamanda, Matlab’ın özel aracı olan sınıflandırma öğrenici aracı (Classification Learner Tool) ile çeşitli makine öğrenmesi yöntemlerine, aykırı Kinect özellik verileri girdi olarak verilir ve eğitilir. Eğitim sonucunda elde edilen doğruluklar belirlendi. Şekil 4.18’de ise bir düşme aktivitesinin çıkarılmış özelliklerinin birbirleri ile karşılaştırılan dağılım grafikleri verilmiştir. Şeki 4.18’deki Maksimum Yükseklik değişkeni, kişinin ayakta durma anındaki yüksekliğini temsil etmektedir. Sınır Kutusunun Kaplama Oranı, sınırlayıcı kutunun kişinin pikselleri taradından işgal edilme oranının temsil etmektedir.




Şekil 4.18. Bir düşme aktivitesinin çıkarılmış özelliklerinin birbirleri ile karşılaştırılan dağılım grafikleri

Şekil 4.19 ve 4.20’de, kullandığımız veri kümesindeki [2] bazı düşme aktivitelerinin ve günlük aktivitelerin R kontrol grafiği sonuçları gösterilmektedir.



Şekil 4.19. Bazı düşme aktivitelerinin R kontrol grafiği sonuçları



Şekil 4.20. Bazı günlük aktivitelerinin R kontrol grafiği sonuçları

Şekil 4.19, sandalyeden yere düşme, biraz yürüyüp sonra yere düşme ve öne doğru düşme aktivitelerinin R kontrol grafiği sonuçlarını göstermektedir. Dikkat edilirse bu üç düşme aktivitesinin R grafiğinde, üst kontrol limiti geçen aykırı noktalar bulunmaktadır. Şekil 4.20’de ise üç farklı günlük, normal aktivitenin R kontrol grafikleri gösterilmiştir. Çalışmamızda günlük aktivitelerin çoğu kontrol limitini geçmemiştir. Yalnızca nadir de olsa bazı günlük aktivitelerinin kontrol limitini geçtiği ve aykırı noktalar gösterdiği gözlemlenmiştir. Bu yüzden kontrol limitini geçen düşme aktivitesine örnek olarak Şekil 4.20’nin c görüntüsü (Yere Uzanıp Yatağın Altına Bakmak) verilmiştir.

5. BULGULAR VE TARTIŞMA

Hareket tanıma ve düşme tespiti için yapılan çalışmalar sonucunda elde edilen bulgular, alt ana başlıklar ile ayrılıp her çalışmanın bulgusu ilgili ana başlığın altında verilmiştir. Alt ana başlıkların kullanılmasının temel sebebi hareket tanıma ve düşme tespiti adı altında iki farklı çalışmanın yapılması ve bu iki farklı çalışma içerisinde de iki farklı yöntemin kullanılmış olmasıdır. Bu yöntemlerin bulgularının daha anlaşılır sunulabilmesi için alt başlıklara ihtiyaç duyulmuştur.

5.1. Hareket Tanıma Bulguları

5.1.1. Makine Öğrenmesi Tabanlı Hareket Tanıma Bulguları

Akıllı telefonun ivme ve jiroskop verilerinden elde edilen UCI HAR veri kümesi kullanılarak özellik çıkarımı yapılmıştır [1]. Özellik çıkarımı için ayrı ayrı üç eksenli ivme verileri; ortalama alma, kök kare ortalama, temel bileşen analizi, otomatik korelasyon, spektral tepe özellikleri, spektral güç özellikleri gibi ön işleme tabi tutulup 66 özellik elde edilmiştir. Verilerin % 70'i (7352), eğitim % 30'u (2947) ise test için ayrılmıştır. Elde edilen özelliklere, eğitim aktiviteleri de eklenip Makine Öğrenmesi sınıflandırma algoritmaları ile sınıflandırılmıştır. Bu sınıflandırma işlemi yapılırken MATLAB'ın sınıflandırma öğrenici aracı kullanılmıştır. En iyi doğruluk veren sınıflandırıcı eğitim modeli olarak seçilmiştir. Tablo 5.1'de verilere uygulanan sınıflandırma metodlarının doğruluk oranları verilmiştir. Oluşturulan sınıflandırma modeli ve test verileri ile hareket tahminleri elde edildi. Tahmin edilen hareketler ile gerçek veriler karşılaştırılıp tahmin doğrulukları bulunmuştur.

Tablo 5.1. Bazı örnek sınıflandırma modellerinin doğruluk sonuçları

Sınıflandırma Modeli	Doğruluk
Torbalı Ağaç	% 95,0
Karesel DVM	% 94,6
Kübik DVM	% 94,5
Karar Ağacı	% 92,9
Ağırlıklı K-En Yakın Komşu	% 91,5

Sonuç olarak 24 farklı sınıflandırma yöntemi sonuçlarından en iyi performansta doğruluğu, % 95,0 ile Topluluk algoritmalarından olan Torbalı Ağaç vermiştir. Tahmin edilen hareketler ile gerçek test verilerin karşılaştırılmasıyla % 90 oranında hareket verileri doğru tahmin edilmiştir. Şekil 5.1'de Torbalı Ağaç algoritmasının pozitif tahmin değeri ile negatif keşif oranı karmaşık

matris sonucu verilmiştir. Şekil 5.2’de ise Torbalı Ağaç modeli gerçek sınıflar ile tahmin edilen sınıf veri sayıları kıyaslaması verilmiştir. Tahmin verilerinin test verilerine göre doğruluk sonucu Tablo5.2’de gösterilmiştir.

Model 1.21					
Doğru sınıf	1	2	3	4	5
	>99%	<1%	<1%		
	<1%	91%		7%	<1%
		<1%	95%	<1%	4%
		9%		93%	
			5%		96%
Pozitif Tahmin Değeri	>99%	91%	95%	93%	96%
Negatif Keşif Oranı	<1%	9%	5%	7%	4%
Tahmin edilen sınıf					

Şekil 5.1. Torbalı Ağaç modeli verimlilik sonuçları

Model 1.21					
Doğru Sınıf	1	2	3	4	5
	1404	2	1		
	1	1195		89	1
		3	2012	3	41
		117		1257	
			108		1118
Tahmin Edilen Sınıf					

Şekil 5.2. Torbalı Ağaç modeli gerçek sınıflar ile tahmin edilen sınıf veri sayıları kıyaslaması


Tablo 5.2. Torbalı Ağaç Sınıflandırma Modeli için Tahmin Verilerinin Test Verilerine Göre Doğruluğu

Sınıflandırma Modeli	Tahmin Verilerinin Test Verilerine göre Doğruluğu
Torbalı Ağaç	% 90,59

5.1.2. UKSB Tabanlı Derin Öğrenme ile Hareket Tanıma Bulguları

Vücuda giyilen bir akıllı telefonda elde edilen sensör verileri kullanılarak standart sapma, ortalama ve kök kare ortalaması ile özellik çıkarımı yapılmış ve dokuz özellik elde edilmiştir. Burada UKSB ağı kullanılarak dizi verilerinin zaman adımlarındaki sınıflandırılması, 200 faklı gizli katman ve beş farklı sınıf (yürüme, durma, oturma, koşma ve dans etme) ile yapılmıştır.

Eğitilen ağ, test verileri ile test edildikten sonra %99'un üzerinde oldukça verimli bir doğruluk sonucu alınmıştır. Şekil 5.3'de UKSB ağı ile kişi hareketinin tahmin sonuçlarının grafiği verilmiştir.




Şekil 5.3. UKSB ağı ile kişi hareketi tahmin grafiği

5.1.3. Parçacık Sürü Optimizasyonu Tabanlı Topluluk Sınıflandırıcı ile Hareket Tespiti Bulguları

İnsan hareket tanıma için önerilen yöntem HAR veri kümesi olarak bilinen bir veri seti üzerinde uygulanmıştır [1]. Kullanılan veri seti 30 farklı kişiye ait 6 farklı hareketi içermektedir.

Her bir hareket için ivme verileri 50 Hz örnekleme frekansı ile 10 saniye kaydedilmiştir. Üç eksenli ivme sensorünün her bir sinyali 128 örnek içermekte olup; yürüme, merdiven çıkma, merdiven inme, oturma, ayakta durma ve uzanma hareketlerini içermektedir. Her hareket için üç eksenli ivme verileri Şekil 5.4'te verilmiştir.



Şekil 5.4. Farklı hareketler için üç eksen ivme sinyalleri

Şekil 5.4'ten gösterildiği gibi farklı hareketlerin sinyalleri birbirine benzer şekilde bir davranış sergilemektedir. Bu yüzden veri üzerinde ön işleme yapılarak toplam 66 özellik çıkarılmıştır. Elde edilen özellikler Tablo 5.3'de gösterilmiştir.

Tablo 5.3. İvme verilerinden elde edilen özellikler

Elde Edilen özellikler	İvme sensörü eksenleri		
	X	Y	Z
Ortalama	1	1	1
Karelerin ortalamasının karekökü	1	1	1
Kovaryans özellikleri	3	3	3
Frekans spektrumu tepe noktaları	6	6	6
Frekans spektrumu tepe noktalarının pozisyonu	6	6	6
Frekans güç bandı	5	5	5

Tablo 5.3’de toplamda 6 adet özellik her bir ivme ekseninden elde edilmiştir. Her bir özellik türü ve eksen için elde edilen özellik sayısı ilgili hücrelerde sayısal olarak verilmiştir. Dolayısıyla toplamda 66 adet özellik elde edilmiştir. Veri kümesi toplamda 10300 adet örnekten oluşmakta olup sınıflandırma işleminde 10 noktalı çapraz doğrulama uygulanmıştır. Sınıflandırma sonucu beş sınıflandırıcı için elde edilen karmaşıklık matrisi Şekil 5.5’te verilmiştir.

	1	2	3	4	5	6
1	1577	49	94	1	1	0
2	68	1377	99	0	0	0
3	78	90	1238	0	0	0
4	0	2	0	1610	166	0
5	0	1	0	183	1772	0
6	0	0	0	0	0	1944

Karar ağacı (Doğruluk:%91)

	1	2	3	4	5	6
1	1698	7	17	0	0	0
2	19	1505	20	0	0	0
3	12	45	1349	0	0	0
4	1	0	0	1541	234	2
5	0	0	1	252	1653	0
6	0	1	0	5	0	1938

Destek Vektör makinalar kübik (Doğruluk:94.0)

	1	2	3	4	5	6
1	1698	4	20	0	0	0
2	12	1509	23	0	0	0
3	17	30	1359	0	0	0
4	1	1	0	1500	273	3
5	0	1	0	271	1634	0
6	0	3	1	6	0	1944

Doğrusal ayırt edici sınıflandırma (Doğruluk:93.5)

	1	2	3	4	5	6
1	1694	14	14	0	0	0
2	66	1438	39	1	0	0
3	57	73	1276	0	0	0
4	1	1	0	1148	597	31
5	0	0	1	345	1599	1
6	2	2	0	11	4	1925

K en yakın komşu (Doğruluk:87.8)

	1	2	3	4	5	6
1	1665	15	42	0	0	0
2	17	1504	23	1	0	0
3	41	51	1314	0	0	0
4	0	1	0	1619	158	31
5	0	0	1	219	1686	1
6	0	0	0	0	0	1944

Destek vektör makinalar Quadratic (Doğruluk oranı: 94.5)

Şekil 5.5. Beş farklı sınıflandırıcının karmaşıklık matrisi

Şekil 5.5’te, gösterilen tablolardaki üst satırlardaki ve sol sütunlardaki 1, yürümeyi; 2, merdiven çıkmayı; 3, merdiven inmeyi; 4, oturmayı; 5, ayakta durmayı; 6, uzanmayı temsil etmektedir. Şekil 5.5’e göre en iyi doğruluk oranı, Karesel DVM ile elde edilmiştir. Karar ağacında maksimum bölme sayısı 100 olarak seçilmiş ve bölme kriteri için Gri indeks kullanılmıştır. Karesel destek vektör makinası için çekirdek fonksiyonu Karesel seçilmiştir. Çoklu sınıflandırma için birine karşı diğeri seçilmiştir. Kübik destek vektör makinasında çekirdek fonksiyonu kübik seçilmiş olup çekirdek ölçeği otomatik seçilmiş ve çoklu sınıflandırma birine karşı diğeri yöntemine göre yapılmıştır. Ağırlıklı en yakın komşu algoritmasına göre mesafe fonksiyonu Öklid seçilmiş ve k değeri 10 olarak alınmıştır.


Beş sınıflandırıcının performansları çoğunluk oylama ile birleştirmek için parçacık sürü optimizasyonu tabanlı bir yöntem seçilmiştir. Amaç en iyi kombinasyonu sağlayan sınıflandırıcıları

seçerek hareket tanıma performansını yükseltmektir. Parçacık sürü optimizasyonun parametreleri Tablo 5.4'te verilmiştir.

Tablo 5.4. Ayırık parçacık sürü optimizasyonun parametreleri

Parametre	Değer
Popülasyon Boyutu	15
Adım Sayısı	50
C_1	1.04
C_2	1.04
w	0.1
Parçacık boyutu	5

Parçacık sürü optimizasyonunda her bir parçacık 5 bit ile ifade edilmektedir. Bir sınıflandırıcı çoğunluk oylamada kullanılacaksa ilgili parçacığın biti 1 kullanılmayacaksa 0 seçilir. Şekil 5.6'da parçacık sürü optimizasyonunun 40 tekrarlama boyunca amaç fonksiyonu gösterilmiştir.




Şekil 5.6. Parçacık sürü optimizasyonun

Şekil 5.6'da gösterildiği gibi parçacık sürü optimizasyonu ile sınıflandırıcı kombinasyonu yapıldığında başarımın %98'in üzerinde olduğu görülmektedir. Tablo 5.5'te ayırık parçacık optimizasyonu ve çoğunluk oylama yöntemine göre elde edilen karmaşıklık matrisi verilmiştir.

Tablo 5.5. Parçacık sürü optimizasyonu ve çoğunluk oylama tabanlı hareket tanıma yönteminin karmaşıklık matrisi

Aktivite Referans Numarası \ Aktivite Referans Numarası	1	2	3	4	5	6
1	1717	1	4	0	0	0
2	9	1533	2	0	0	0
3	32	48	1326	0	0	0
4	0	0	0	1748	30	0
5	0	0	0	1	1905	0
6	0	0	0	0	0	1944

Tablo 5.5'e göre parçacık sürü optimizasyonu karar ağacı, karesel destek vektör makineler ve doğrusal ayırt edici sınıflandırıcıları birleştirerek en iyi performansı elde etmiştir. Sınıflandırma başarımlarını ölçmek için F1, geri çağırma, keskinlik parametreleri ile birlikte doğruluk oranı kullanılmıştır. Şekil 5.7'de her bir durum için bu sonuçlar verilmiştir.



Şekil 5.7. Farklı performans ölçümlerine göre algoritmaların başarımları

Şekil 7'den de görüldüğü gibi farklı başarımlar ölçümlerine göz önüne alındığında hepsinde önerilen yöntemin daha iyi sonuçlar verildiği görülmektedir. Birden çok sınıflandırma yönteminin birleştirilmesi ve buna göre uygun olanların kombinasyonu ile yapılan sınıflandırma işlemi oldukça yüksek başarımlar vermektedir.

Önerilen yöntemin sonuçları literatürde hareket tanıma için geliştirilen diğer teknikler ile karşılaştırılmıştır. Bu amaçla aynı veri kümesi üzerinde ivme, jiroskop ve diğer ekstra sensörlerden elde edilen özellikleri kullanan çalışmalar seçilmiştir. Karşılaştırma sonuçlarında kullanılan sensörler, özellik çıkarımı ve başarımları verilmiştir. Karşılaştırma sonuçları Tablo 5.6’da verilmiştir.

Tablo 5.6. Önerilen yöntemin farklı yöntemler ile karşılaştırma sonuçları

Referans	Kullanılan sensörler	Özellik çıkarımı	Sınıflandırıcı	Doğruluk oranı (%)
[6]	Üç eksen ivme	Zaman ve frekans domeni özellikleri	Çoklu sınıflandırma	95.37
[21]	Jiroskop ve ivme	Zaman ve frekans özellikleri, temel bileşen tabanlı özellik seçimi	Bayes sınıflandırıcı	90.10
[22]	Üç eksen ivme	Zaman domeninde istatistiksel özellikler	Dinamik doğrusal ayrıştırıcı	92.86
[26]	Jiroskop ve ivme	Gradyan histogramı ve merkezi Fourier tanımlayıcıları	Destek vektör makinalar	92.67
Önerilen Yöntem	Üç eksen ivme	Zaman ve frekans domeni özellikleri	PSO tabanlı topluluk sınıflandırıcı	98.77

Tablo 5.6’da jiroskop ve ivme sensorları kullanıldığında elde edilen sonuçlar listelenmiştir. Önerilen yöntemler aynı veri kümesi üzerinde uygulanmıştır. Önerilen çalışmada kullanılan veri seti 10300 örnekten oluşmaktadır. Fakat bazı çalışmalarda veri kümesi boyutu daha düşük tutulmuştur. Tablo 5.6’da verilen ilk çalışmada farklı sınıflandırma yöntemleri birleştirilerek elde edilen özelliklere göre sınıflandırma başarımları arttırılmaya çalışılmıştır. Wang ve ark. [21] tarafından sunulan çalışmada ivme ve jiroskop sinyallerinden özellik çıkarımı yapılmış ve iki bilgi birleştirilerek hareket tanıma başarımları arttırılmaya çalışılmıştır. Chen ve ark. [22]’nin sunduğu çalışmada zaman domeninde bazı istatistiksel özellikler çıkarılmıştır. Temel katkı noktası ise dinamik doğrusal ayrıştırıcı tarafında yapılmıştır. Jain ve Kanhangad [26] önerdikleri çalışmada jiroskop ve ivme sinyallerinden tek boyutlu gradyan histogramı ve merkezi Fourier tanımlayıcıları ile özellikler elde etmişlerdir. Elde edilen özellikler destek vektör makinalar ile sınıflandırılmıştır. Tablo 5.6’da verilen sonuçlar karşılaştırıldığında çoklu sınıflandırıcıların en uygun biçimde birleştirilmesi toplam hareket tespit performansını önemli ölçüde arttırmaktadır.


5.2. Düşme Tespiti Bulguları

5.2.1. 1B-YİD ve Aşırı Öğrenme Makinesi Metotları Bulguları


Çalışmamızda Michel Kepski'nin yayınlamış olduğu hazır verilerden yararlanılmıştır [2]. Burada 70 farklı hareketin ivme verileri kullanılmıştır. Bu 70 verinin 40 tanesi günlük normal aktivitelerdir ve 30 tanesi de düşme aktiviteleridir. Aşağıda normal günlük aktivitelerin ve düşme aktivitelerinin bazı örnek ivme verileri verilmiştir. İlk önce günlük normal ve düşme aktivitelerinin ivme verilerini aldık. Bu verilerden normal ve düşme aktivitelerini ayırt etmek için sınıf etiketleriyle verileri etiketledik. İvme verilerinin büyüklükleri hesaplandı. 3 eksenli ivme verilerinin büyüklüğü formül Denklem 5.1'de gösterildiği gibi hesaplanmıştır.

$$Acc_{büyüklik}(t) = \sqrt{(Acc_X(t)^2 + Acc_Y(t)^2 + Acc_Z(t)^2)} \quad (5.1)$$


Şekil 5.8'te, sandalyeye oturma eyleminin x, y, z boyutlarındaki ivme verilerini ve bu verilerin büyüklük verilerini göstermektedir. Şekil 5.9'da dört farklı günlük normal aktivitelerin büyüklük grafikleri verilmiştir.



Şekil 5.8. Üç eksen ivme verilerinin grafikleri ve sandalyeye oturma eylemi için onların büyüklük grafiği




Şekil 5.9. Dört farklı günlük aktivitenin ivme büyüklüklerinin grafikleri




Şekil 5.10. Bazı düşme aktiviteleri büyüklük grafikleri

Şekil 5.9'daki günlük aktiviteler birbirinden farklı olmasına rağmen ani değişiklikler içermiyor. Fakat Şekil 5.10'daki düşme aktiviteleri ise ani değişiklikler içermektedir. Bu bilgi normal ve düşen etkinlikleri ayırt etmek için kullanılabilir. 1B-YİD tanımlayıcı yöntemi ile özellik çıkarımı yapılmıştır. Elde edilen normal ve düşme aktivitelerinin bazı histogram verileri, Şekil 5.11 ve 5.12'de gösterilmiştir.



Şekil 5.11. Bazı normal aktivitelerin 1B-YİD ivme verileri ve histogram girafikleri



Şekil 5.12. Bazı düşme aktivitelerinin ivme verisi grafikleri ile histogram grafikleri

1B-YİD metodu ile özellik çıkarımı yaptıktan sonar verileri Aşırı Öğrenme Makinesi (AÖM) ile eğitilmiştir. Tablo 5.7’de AÖM, Destek Vektör Makinesi (DVM) ve Yapay Sinir Ağı (YSA) ile elde edilen sonuçları göstermektedir. AÖM’nde, eğitim verilerinden elde edilen karmaşık matrisin pozitif orano % 98,3 olarak bulundu. Bulunan sonuç, YSA ve DVM ile karşılaştırılmıştır. İvme verileri, YSA ile test edildiğinde karmaşıklık matrix değeri, % 80 doğruluk olarak bulundu. Veriler DVM makine öğrenmesi algoritması ile eğitildiğinde % 82,9 doğruluk elde edilmiştir.

Tablo 5.7. AÖM ve DVM ile YSA Sınıflandırıcıların doğruluk sonuçları

Sınıflandırma Modeli	Doğruluk
AÖM	% 98,3
DVM	% 82,9
YSA	% 80

Son olarak eğitim ve test verileri ayrı ayrı Aşırı Öğrenme Makinesi yöntemi ile test edilmiştir. Eğitim verilerinin doğruluğu, % 100; test verilerinin doğruluğu, %90 olarak elde

edilmiştir. AÖM ile elde edilen doğruluk sonucu literatürdeki bazı çalışmalarla karşılaştırıldı. Bu karşılaştırmalar Tablo 5.8’ gösterilmektedir. Tablo 5.8’de farklı sensörler ile yapılmış düşme tespiti sonuçları verilmiştir. Ancak referans numarası 21 olarak verilen Kepki ve Kwolek çalışmalarında kullandıkları ivme verileri ile bu tez çalışmasında kullanılan ivme verileri aynıdır. Kepski ve Kwolek, ivme ve derinlik verilerini bir arada kullanarak düşmeyi tespit etmişler. Çalışmalarında, eşik tabanlı bir algoritma, ivmeölçerden gelen verilere dayanarak, olası bir düşüş durumunda düşüş olayını doğrulamak için bulanık sistemi başlatır. Bu tez çalışmasında ise sadece ivmeölçer verileri kullanılmıştır. 1B-YİD yöntemiyle çıkarım özelliklerine sahip olduk ve verilerimizi AÖM sınıflandırıcısı ile eğittik. Bu tez çalışmasında sadece ivmeölçer verilerini kullanılmasına rağmen düşme aktiviteleri, günlük aktivitelerden % 98,3 doğrulukla ayrılmıştır.

Tablo 5.8. Önerilen AÖM yöntemi ile elde edilen doğruluk sonucu ve literatürdeki bazı çalışmaların karşılaştırılması

Yöntemler	Sensörler	Özellik Çıkarımı	Doğruluk	Referans
AÖM	3 eksenli ivmeölçer	Toplam ivme vektörlerinin toplamı (SV_{total}) ve 1B-YİD	% 98,3	Önerilen yöntem
Özellik Sinyallerinin Eşik Değeri	3 eksenli ivmeölçer ve jiroskop	Toplam ivme vektörlerinin toplamı (SV_{total}), üst düşme eşik değeri ve alt düşme eşik değeri	Ortalama % 96	[8]
Eşik değerleri ve Çevrim İçi Hesaplanan Parametreler	3 eksenli ivme sensörü ve oryantasyon sensörü	Toplam ivme vektörlerinin toplamı (SV_{total})	Ortalama %73	[73]
Denetimli Rastgele Orman	Zemin sensörü	Fourier Dönüşümü, minimum veya maksimum değerler, ortalama, varyasyon	Ortalama % 94,4	[17]
Bir Sınıf Destek Vektör Makinesi	İki mikrofon	Kaynak Ayırma Tekniği, Mel-frekans cepstral katsayısı (MFCC)	Ortalama % 95	[12]
Eşik Değer ve Bulanık Mantık	İvmeölçer ve Kinect	Toplam ivme vektörlerinin toplamı (SV_{total}), zemin düzlemi çıkarımı, H/W , H/H_{max} , D , $max(\sigma_x, \sigma_z)$	%97,14	[21]

Sonuç olarak, bu çalışmada önerilen yöntemin daha verimli sonuçlar elde ettiğini kanıtlandı. Yöntemimizi literatürde düşme saptaması için yapılan bazı çalışmalarla da karşılaştırdık. Diğer çalışmalara kıyasla verimli sonuçlar elde edildi gösterildi.


5.2.2. Kontrol Grafiği Metodu Bulguları

Bu tez çalışmasında Michal Kepski ve Bogdan Kwolek'in çalışmalarında kullanmış oldukları hazır ivme ve Kinect derinlik verileri kullanılmıştır [2]. Bu veri kümesi 30'u düşme, 40'ı günlük aktiviteleri içermektedir. Düşme aktiviteleri iki Microsoft Kinect kamera ve ilişkili ivme verileri ile kaydedilmiştir. Günlük aktiviteler ise bir kamera ve ivmeölçer ile kaydedilmiştir. Sensör verisi 60 Hz de PS Move ve 256 Hz' li x-IMU aletleri ile toplanmıştır. Derinlik verileri PNG16 formatında kaydedilmiş ve milimetre cinsinden derinlik (d), Denklem 5.2'ye göre yeniden ölçeklendirilmiştir.


$$d = \frac{C_i.P(x,y)}{65535} \quad (5.2)$$

Burada d harfi, milimetre cinsinden derinliği, C_i i'ninci kameranin ölçek oranını ve $P(x,y)$ ise PNG16 görüntüsünün (x,y) konumundaki piksel değerini belirtmektedir. Düşme dizisi: $C_0=6000$ ve $C_1=3640$ ' dır. Günlük aktiviteler: $C_0=7000$.

Bu hazır veri kümesi aynı zamanda zaman uyumlu (eş zamanlı) ivme verilerini de içermektedir. Görüntü çerçevesine karşılık gelen zaman uyumlu veriler; çerçeve numarasını, dizilimin başlamasından bu yana geçen milisaniye cinsindeki süreyi ve ara değerler ekli ivmeölçer verisini (SV_{total}) içermektedir. Ham ivme verileri ise dizilimin başlamasından itibaren süreyi ve ivme verilerini (SV_{total} , A_x , A_y , A_z) içermektedir. Şekil 5.13 ve Şekil 5.14'te gerçek hayattan toplanan yürüme, koşma, merdivenden çıkma ve düşme aktivitelerinin ivme ve açısal hız verileri verilmiştir. İki şekli karşılaştırsak günlük aktivitelerdeki (Şekil 5.13) ivme verilerinde ani ve büyük değişiklikler yok, fakat düşme aktivitesinde (Şekil 5.14) ani ve büyük değişikliğin olduğu kolaylıkla gözlemlenebilir. İvme verilerini kullanarak düşme aktivitelerindeki bu ani değişiklikler, kontrol grafiği yöntemi ile aykırı noktalar olarak kolaylıkla belirlenebilmektedir.



Şekil 5.13. Bazı günlük aktivitelerin ivme ve açısal hız grafikleri




Şekil 5.14. Düşme eyleminin ivme ve açısal hız grafikleri

Potansiyel düşme olarak belirlenen aktivitelerden daha doğru sonuçlar elde etmek için Kinect verilerinden elde edilen özellikli veri kümesi kullanılmıştır. Bu veri kümesinde bulunan özellikler:

- Etiket verileri (-1: kişi zemine uzanmış demek, 1: Kişi uzanmamış demek),
- Yükseklik genişlik oranı (görüntüde kişiyi sınırlayan sınır kutusunun en boy oranı),
- Büyük / küçük eksen oranı, sınırlayıcı kutunun kişinin pikselleri tarafından işgal edilme oranı,
- X eksen ve Z eksen (derinlik) için merkeze göre piksellerin standart sapması,
- Çerçeve içindeki insan yüksekliği ile ayakta durma anındaki insan yüksekliğinin (maksimum yükseklik) oranı,
- Gerçek yükseklik (milimetre cinsinden), kişi merkezinin zemine olan uzaklığı,

- P40 (40 cm yüksekliğinde bir küp şekline ait ve zemine yerleştirilmiş nokta bulutlarının sayısının, kişinin yüksekliğine eşit yükseklikteki küp şekline ait nokta bulutlarına oranı).

Çalışmada öncelikle üç eksenli ivme verileri kontrol grafiği (controlchart) fonksiyonuna verilmiştir. Kontrol grafiğinin düşme ve günlük aktiviteleri birbirinden yaklaşık % 91 oranında düşme ve günlük aktiviteleri doğru bir şekilde bulduğu kanıtlanmıştır. Şekil 5.15'te kontrol grafiğine verilen 70 aktivitenin aykırı nokta sayılarını gösteren bar grafiği verilmiştir. Şekildeki aktivitelerin son 30'u gerçek hayatta olmuş olan bazı düşme aktiviteleridir. Tabi ki düşme eylemi ani gerçekleşen bir olay olduğundan, ani değişimler kontrol grafiğinde fark edildi. Bu yüzden kontrol grafiği tüm bu düşme aktivitelerini doğru bir şekilde tespit etmiştir. İlk 40 aktivite normal günlük aktivitedir, fakat bu aktivitelerin 6'sında da ani değişiklikler kontrol grafiği tarafından fark edilmiştir. Kontrol grafiğindeki ani düşmeler bu çalışmada potansiyel düşme olarak kabul edildiğinden yanlış sonuç vermiştir. Ama sonuç olarak % 91 doğrulukla düşme ve günlük aktiviteler tespit edilmiştir. Bu çalışmada kontrol grafiğindeki bu eksikliği giderebilmek için elde edilen bu düşme verileri, potansiyel düşme olarak kabul edilmiştir ve bu verilerin ilgili görüntü verilerine gidilip, o verilerdeki düşme etiketleri incelendi. Ve görüntü verilerinde uzanma etiketi var (uzanma etiketi düşme eylemi olarak kabul edilmiştir) ise potansiyel düşme aktivitesinde düşmenin var olduğu doğrulanmıştır. Böylelikle düşme olayı Kinect görüntü verileriyle doğrulanmıştır.



Şekil 5.15. 70 farklı düşme ve günlük aktivitelerin kontrol grafiği sonucunda elde edilen aykırı noktalarını gösteren bar grafiği

Daha sonra kontrol grafiğinden elde edilen potansiyel düşme verilerinin olduğu aktivitelerden, aykırı noktaların 5 çerçeve öncesi ve 5 çerçeve sonrası alınarak her bir potansiyel düşme aktivitesinden toplam 11 örnek alınmıştır. Matlab'ın bir aracı olan sınıflandırma öğrenici aracı yardımıyla birçok makine öğrenmesi algoritmasıyla elde edilen 9 özellikli potansiyel düşme verileri, çapraz doğrulama katı 10 seçilerek eğitilmiştir. Sınıflandırma algoritmalarının birçoğu % 100 verim ile sonuçlanmıştır. Tablo 5.9'da bu algoritmaların bazılarının sonuçları gösterilmektedir. Bu algoritmaların örnek olarak Şekil 5.16'te İyi Gauss DVM algoritmasının doğru pozitif ve yanlış negatif oranları karışıklık matrisi verilmiştir. Şekil 5.17'da ise İyi Gauss DVM algoritmasının olumlu tahmin değeri ile yanlış keşif oranı karışıklık matrisi sonuçları verilmiştir.



Şekil 5.16. İyi Gauss DVM algoritmasının doğru pozitif ve yanlış negatif oranları karışıklık matrisi



Şekil 5.17. İyi Gauss DVM algoritmasının olumlu tahmin değeri ile yanlış keşif oranı karışıklık matrisi sonuçları

Tablo 5.9. Potansiyel düşme verilerinin makine öğrenmesi algoritmaları ile eğitilmeleri sonucunda elde edilen doğruluklar

Algoritma	Doğruluk Sonucu
Ağaç	% 100
Karesel Diskriminant	% 100
Logistik Regresyon	% 100
Gauss Naif Bayes	% 100
Doğrusal DVM	% 100
İnce Gauss DVM	%99,5
Torbalı Ağaçlar	% 99,5
Alt Uzay Ayırıcı	%99,3
K-En Yakın Komşu	% 97,3

Kepski ve Kwolek [2], çalışmalarında eşik değeri belirleyerek düşme eylemini düşme olmayan eylemden ayırt etmeye çalışmışlardır. Bu tez çalışmasında da eşik değeri kullanılıyor fakat eşik değeri, manuel olarak verilmiyor. Kontrol grafiği kullanılarak eşik değerleri, o anki aktivite veri kümesi için otomatik olarak belirleniyor (üst kontrol sınır ve alt kontrol sınır). Böylece aktivite veri kümesine uygun eşik değerleri elde edilmektedir. Birçok makine öğrenmesi yöntemleri ile verilerimiz eğitildiğinde % 100 ve % 100'e yakın doğruluk değerleri elde edilmiştir.

6. SONUÇLAR

- 1) İnsan hayatını kolaylaştırmak ve düşen bireylere etkili ilk yardımın yapılması için bu tez çalışmasında insan aktivite tespiti ve kişi düşme tespiti üzerine çalışmalar yapıldı. Çalışmanın asıl odak noktası, özellikle yaşlılarda sıklıkla görülebilen düşme eylemini etkili ve verimli bir şekilde tespit etmek, böylelikle düşen bireye ilk yardımın etkili bir şekilde yapılmasına katkı sağlamaktır. Düşme tespitinin yapılabilmesi için kişinin günlük normal aktivitelerinin tanınması ve daha sonra düşme eylemi ile günlük normal aktivitelerin birbirinden ayrılması gerektiği düşünüldü. Bu yüzden öncelikle kişi aktivite tanımı üzerine yöntemler geliştirildi. Bu yöntemler: Makine öğrenmesi, UKSB tabanlı derin öğrenme yöntemi ve parçacık sürü optimizasyonu tabanlı kişi tespiti yöntemleridir. Kişi normal günlük aktivite tespiti çalışmalarından sonra kişi düşme tespiti üzerine yöntemler geliştirildi. Bu yöntemlerden biri, bir boyutlu yerel ikili desen özellik çıkarımı ile aşırı öğrenme makinesi yöntemidir. Bir diğer yöntem ise kontrol grafiği ile ivme verilerinden potansiyel düşme anlarının belirlenmesi ve bu anlardaki ilgili Kinect görüntülerine gidilip düşmenin olup olmadığının doğrulanmasıdır.
- 2) Günlük normal aktivitelerden alınan ivme verileri kullanılarak kişi hareket tespiti makine öğrenmesi yöntemleri ile Uzun Kısa Süreli Bellek (UKSB) yöntemi ile test edildi. UKSB tabanlı derin öğrenme yönteminin makine öğrenmesi algoritmalarına göre daha iyi sonuçlar verdiği kanıtlandı.
- 3) Büyük veri kümeleri üzerinde tek bir sınıflandırıcı ile yüksek başarımın elde edilmesi çoğu zaman zordur. Birden fazla sınıflandırıcının uygun şekilde birleştirilmesi ile daha yüksek başarımlar elde edilebilir. Bu çalışma kapsamında önerilen topluluk seçim yöntemi parçacık sürü optimizasyonu tabanlı bir topluluk kullanarak bir araya getirilmekte ve sınıflandırma performansını en fazla arttıran en iyi sınıflandırıcı grup otomatik olarak seçilmektedir. Çalışma içerisinde kullanılan sınıflandırıcılar Kübik Destek Vektör Makineler (KDVM), karar ağacı (KA), K-En Yakın Komşu Sınıflandırıcı (KEYK), Doğrusal ayırt edici sınıflandırma ve Gauss Destek Vektör Makineleri (GDVM)'dir. Parçacık sürü optimizasyonun orijinal versiyonu reel sayılar üzerinde çalışarak reel uzayda işlem yapar. Hem hız hem de pozisyon güncellemesi reel sayılar üzerinde verilen aralıkta yapılır. Burada önerilen yöntem farklı sınıflandırıcılar içerisinde hangi kombinasyondan sınıflandırıcı seçilirse daha iyi bir sınıflandırma performansı elde edileceğidir. Bu yüzden ayrık parçacık sürü optimizasyonu önerilmiştir. Amaç en iyi kombinasyonu sağlayan sınıflandırıcıları seçerek hareket tanıma performansını yükseltmektir. Sonuç olarak

parçacık sürü optimizasyonu ile sınıflandırıcı kombinasyonu yapıldığında başarımın %98'in üzerinde olduğu görüldü.

- 4) Düşme tespiti için bir boyutlu yerel ikili desen metodu ile özellik çıkarımı yapıldı ve çıkarılan bu özellikler aşırı öğrenme makinesi (AÖM) eğitildi. AÖM' de, eğitim verilerinden elde edilen karmaşık matriksin pozitif oranı % 98,3 olarak bulundu. Bulunan sonuç, YSA ve DVM ile karşılaştırıldı. İvme verileri, YSA ile test edildiğinde karmaşık matriks değeri, % 80 doğruluk olarak bulundu. Veriler DVM makine öğrenmesi algoritması ile eğitildiğinde % 82,9 doğruluk elde edildi. YSA ve DVM metodlarının dışında literatürde yapılmış bazı düşme tespiti yöntemleri ile de önerdiğimiz AÖM yöntemini karşılaştırdığımızda oldukça iyi bir sonuç elde edildiği gözlemlenmiştir.
- 5) Geçiş eylemli aktiviteleri (eğilip yerden bir şey alıp kalkmak gibi) ile düşme eylemini ayırt etmek zordur. Bu zorluğu aşmak amacıyla kontrol grafiğini kullanılmıştır. Önerilen yöntemde kontrol grafiği kullanılarak ivme verilerindeki aykırı noktalar bulunmuştur ve bu aykırı noktalar potansiyel düşme anları olarak kabul edilmiştir. Daha sonra potansiyel olarak düşmenin olduğu aktivitelerin ilgili Kinect özellik verilerine gidip o verilerin etiket değeri 1 (1:uzanma, -1: uzanmama) ise düşme eylemi doğrulanmıştır. % 91 doğrulukla düşme ve günlük aktiviteler tespit edilmiştir. Daha sonra potansiyel düşme verilerinin olduğu aktivitelerden, aykırı noktaların 5 çerçeve öncesi ve 5 çerçeve sonrası alınarak her bir potansiyel düşme aktivitesinden toplam 11 veri alındı. Matlab'ın bir aracı olan sınıflandırma öğrenici (Classification Learner) yardımıyla birçok makine öğrenmesi algoritması ile elde edilen 9 özellikli potansiyel düşme verileri, eğitildi. Sınıflandırma algoritmalarının birçoğu % 100 verim ile sonuçlandı.

ÖNERİLER

- 1) Bu tez çalışmasında, açık kaynak verileri ile gerçek hayattan elde edilen veriler kullanılmıştır. Çalışmada yürüme, merdivenden çıkma, merdivenden inme, oturma, ayakta durma, uzanma gibi normal aktiviteler ile düşme eylemi tespit edilmiştir. Önerilen yöntemlerle daha farklı aktivitelerin tespiti üzerine çalışmalar yapılabilir.
- 2) Düşme tespiti için önerilen metotlar kişi düşme sensör sistemlerinde kullanılabilir ve etkili düşme tespitleri yapılabilir.
- 3) Bu tez çalışmasında önerilen yöntemlerde, akıllı telefon ivme verileri kullanıldı. Diğer vücuda monte edilen sensörlere nazaran, birçok kişinin günlük yaşamında, birçok sebepten dolayı (iletişim, mesajlaşma, veri paylaşımı, sosyal medya gibi) sıklıkla kullandığı akıllı telefonlar, düşme tespiti yöntemlerinde daha sık kullanılabilir. Fakat insan sağlığını olumsuz etkileyebilen radyasyon gibi zararlı ışınların zararını azaltabilecek akıllı telefon teknolojileri geliştirilmelidir. Böylelikle son yılların en çok kullanılan ve taşınan aleti olan akıllı telefonların uzun süre kişi tarafından taşınmasının sebep olduğu sağlık problemlerinin önüne geçilebilir.
- 4) Tez çalışmasındaki önerilen yöntemde, kontrol grafiği ile kişi düşme tespiti için ivme verilerinden elde edilen potansiyel düşme anları Kinect özellik verileri ile doğrulanıyor. Düşme tespiti için Kinect verileri oldukça kullanışlıdır. Kinect sensörü ile kişi uzaktan rahatlıkla izlenilebilir ve Kinect'ten elde edilen derinlik görüntülerinden analizler yapılabilir. Özellikle ev ortamında, renkli görüntü alan kameralarla kişi düşme tespiti yapıldığında kişinin mahremiyeti tam olarak korunamaz. Bu yüzden renkli kamera ile izlenen kişi, günlük normal aktivitelerini yapmaktan kaçınabilir ve kendini rahatsız hissedebilir. Kinect derinlik verileri ile kişinin mahremiyeti bir boyutta korunduğu için bu problemin önüne geçilmektedir. Derinlik görüntüleri ile kişinin uzaktan izlenmesi, vücutta bir sensör taşıma gereksinimi duyulmadığından hem konfor hem de mahremiyet bakımından izlenen kişiye avantaj sağlamaktadır. Bu yüzden Kinect verileriyle etkili ve verimli daha çok düşme tespiti yöntemleri geliştirilebilir.

KAYNAKLAR

- [1] Anguita, D., Ghio, A., Oneto, L., Parra, X. ve Reyes-Ortiz, J. L., (2013). A Public Domain Dataset for Human Activity Recognition Using Smartphones., *21th European Symposium on Artificial Neural Networks*, Computational Intelligence and Machine Learning, ESANN 2013.
- [2] Kwolek, B., Kepski, M., (2014). Human fall detection on embedded platform using depth maps and wireless accelerometer, *Computer Methods and Programs in Biomedicine*, cilt 117, no. 3, pp. 489-501.
- [3] Karantonis, D.; Narayanan, M.; Mathie, M.; Lovell, N.; Celler, B. (2006). Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring, *IEEE Transactions on Information Technology in Biomedicine*, cilt 10, no. 1, pp. 156-167.
- [4] Gao, L.; Bourke, A. K.; Nelson, J. (2012). A comparison of classifiers for activity recognition using multiple accelerometer-based sensors, *2012 IEEE 11th International Conference on Cybernetic Intelligent Systems (CIS)*, pp. 149-153.
- [5] Ronao, C. A.; Cho, S.-B. (2014) Human activity recognition using smartphone sensors with two-stage continuous hidden Markov models, *2014 10th International Conference on Natural Computation (ICNC)*, pp. 681-686.
- [6] Dernbach, S., Das, B., Krishnan, N. C., Thomas B. L. ve Cook, D. J. (2012). Simple and Complex Activity Recognition through Smart Phones, *2012 Eighth International Conference on Intelligent Environments*, pp. 214-221, 2012.
- [7] Aydin, I. (2018). Fuzzy Integral and Cuckoo Search Based Classifier Fusion for Human Action Recognition, *Advances in Electrical and Computer Engineering*, cilt 18, no. 1, pp. 3-10, 2018.
- [8] Huynh, Q., Nguyen, U., Irazabal, L., Ghassemian, N., Tran, B. (2015). Optimization of an Accelerometer and Gyroscope-Based Fall Detection Algorithm, *Journal of Sensors*, pp. 1-8. 10.1155/2015/452078.
- [9] Georgakopoulos, S. V., Tasoulis, S. K., Maglogiannis I. ve Plagianakos, V. P. (2015). On-Line Fall Detection via Mobile Accelerometer Data, *Artificial Intelligence Applications and Innovations*, Cham.
- [10] Ranasinghe, S. , Machot, F. A. ve Mayr., H. C. (2016). A review on applications of activity recognition systems with regard to performance and evaluation, *International Journal of Distributed Sensor Networks* , cilt 12, no. 8, 2016.
- [11] Chaccour, K. ve Darazi, R. (2015). Smart Carpet using differential piezoresistive pressure sensors for elderly fall detection, *2015 IEEE 11th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, ss. 225-229.
- [12] Khan, M. S., Yu, M., Feng, P., Wang L. ve Chambers, J. (2015). An unsupervised acoustic fall detection system using source separation for sound interference suppression, *Signal Processing*, cilt 110, pp. 199-210.
- [13] Siddiqi, M. H., Ali, R., Rana, M. S., Hong, E.-K., Kim, E. S. ve Lee, S. (2014) Video-based human activity recognition using multilevel wavelet decomposition and stepwise linear discriminant analysis, *Sensors*, cilt 14, pp. 6370-6392.
- [14] Shih, H.-C. (2017) A Survey on Content-aware Video Analysis, *IEEE TRANSACTIONS ON CIRCUITS AND SYSTEMS FOR VIDEO TECHNOLOGY*, cilt 99, no. 9.
- [15] Emonet, R., Varadarajan, J. ve Odobez, J.-M. (2011). Multi-camera open space human activity discovery for anomaly detection, *2011 8th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, pp. 218-223.

- [16] Ryoo, M. S. (2011). Human activity prediction: Early recognition of ongoing activities from streaming videos, *2011 International Conference on Computer Vision*, pp. 1036-1043.
- [17] Minvielle, L. , Atiq, M. , Serra, R., Mougeot, M. ve Vayatis, N. (2017). Fall detection using smart floor sensor and supervised learning, *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*.
- [18] Scheffer, A. C., Schuurmans, M. J., Dijk, N., Hooft, T. ve Rooij, S. E. (2008). Fear of falling: measurement strategy, prevalence, risk factors and consequences among older persons, *Age and Ageing*, cilt 37, pp. 19-24, 2008.
- [19] Yang, L., Ren, Y. ve Zhang, W. (2016). 3D depth image analysis for indoor fall detection of elderly people, *Digital Communications and Networks*, cilt 2, pp. 24-34.
- [20] Kepski, M. ve Kwolek., B. (2015). Embedded system for fall detection using body-worn accelerometer and depth sensor, *2015 IEEE 8th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*.
- [21] Kwolek, B. ve Kepski, M. (2016). Fuzzy inference-based fall detection using kinect and body-worn accelerometer, *Applied Soft Computing*, cilt 40, pp. 305-318, 2016.
- [22] Ann, O. C. ve Theng, L. B. (2014). Human activity recognition: A review, *2014 IEEE International Conference on Control System, Computing and Engineering (ICCSCE 2014)*, pp. 389-393.
- [23] He, Y., Gao, B., Sophian, A. ve Yang, R. (2017). Magnetic Sensor Based Pulsed Eddy Current for Defect Detection and Characterization, *Transient Electromagnetic-Thermal Nondestructive Testing*, pp. 7-35.
- [24] Soman, K., Loganathan, R. ve Ajay, V. (2011). Machine Learning with Support Vector Machines, *Machine Learning with SVM and Other Kernel Methods*, New Delhi, p. 1
- [25] LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning, *Nature Publishing Group, a division of Macmillan Publishers Limited*, cilt 521.
- [26] Huang, P. ve Hsu., L.-P. (2005). Development of a wearable biomedical health-care system, *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 1760-1765.
- [27] Li, F., Shirahama, K., Nisar, M. A., Köping L. ve Grzegorzec, M. (2018). Comparison of Feature Learning Methods for Human Activity Recognition Using Wearable Sensors, *Sensors (Basel, Switzerland)*.
- [28] Köping, L., Shirahama, K. ve Grzegorzec, M. (2018). A general framework for sensor-based human activity recognition, *Computers in Biology and Medicine*, cilt 95, pp. 248-260.
- [29] Bourke, A. K., O'Brien, J. V. ve Lyons, G. M. (2007). Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm, *Gait & Posture*, cilt 26, pp. 194-199.
- [30] Passaro, V., Cuccovillo, A., Vaiani, L., Carlo, M., & Campanella, C. E. (2017). Gyroscope Technology and Applications: A Review in the Industrial Perspective. *Sensors (Basel, Switzerland)*, 17(10), 2284. doi:10.3390/s17102284
- [31] Bourke, A. K., O'Brien, J. V. ve Lyons, G. M. (2007). Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm, *Gait & Posture*, cilt 26, pp. 194-199.
- [32] Li, Q., Stankovic, J. A., Hanson, M. A., Barth, A. T., Lach, J. ve Zhou, G. (2009). Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information, *2009 Sixth International Workshop on Wearable and Implantable Body Sensor Networks*, 3-5 .
- [33] Kangas, M., Konttila, A., Lindgren, P., Winblad, I. ve Jämsä, T. (2018). Comparison of low-complexity fall detection algorithms for body attached accelerometers, *Gait & Posture*, cilt 28, pp. 285-291.

- [34] Doukas, C., Maglogiannis, I., Tragkas, F., Liapis, D. ve Yovanof, G. (2007). Patient Fall Detection using Support Vector Machines, *Int Fed Inf Process*, cilt 247.
- [35] Gibson, R. M., Amira, A., Ramzan, N., la-Higuera, P. C.-d. ve Pervez, Z. (2016). Multiple comparator classifier framework for accelerometer-based fall detection and diagnostic, *Applied Soft Computing*, cilt 39, pp. 94-103.
- [36] Abbate, S., Avvenuti, M., Cola, G., Corsini, P., Light, J. ve Vecchio, A. (2011). Recognition of false alarms in fall detection systems, *2011 IEEE Consumer Communications and Networking Conference (CCNC)*, 9-12.
- [37] Abbate, S., Avvenuti, M., Bonatesta, F., Cola, G., Corsini, P. ve Vecchio, A. (2012). A smartphone-based fall detection system, *Pervasive Mob Comput*, cilt 8.
- [38] Fang, S. H., Liang, Y. C. ve Chiu, K. M. (2012). Developing a mobile phone-based fall detection system on android platform, *Hong Kong: Institute of Electrical and Electronics Engineers*.
- [39] Kau, L. J. ve Chen, C. S. (2015). A Smart Phone-Based Pocket Fall Accident Detection, Positioning, and Rescue System, *IEEE Journal of Biomedical and Health Informatics*, cilt 19, pp. 44-56.
- [40] Li, Y., Ho, K. C. ve Popescu, M. (2012). A microphone array system for automatic fall detection, *IEEE Trans Biomed Eng*, cilt 59.
- [41] Rimminen, H., Lindström, J., Linnavuo, M. ve Sepponen, R. (2010). Detection of falls among the elderly by a floor sensor using the electric near field, *IEEE Trans Inf Technol Biomed*, cilt 14.
- [42] Miguel, K., Brunete, A., Hernando, M. ve Gambao, E.(2017). Home Camera-Based Fall Detection System for the Elderly, *Sensors*, cilt 17.
- [43] Cucchiara, R., Rita, H., Prati, A., Andrea, O., Vezzani, R. ve Roberto, C. (2007). A multi-camera vision system for fall detection and alarm generation, *Expert Syst*, cilt 24.
- [44] Wang, M., Huang, C. ve Lin, H. (2006). An Intelligent Surveillance System Based on an Omnidirectional Vision Sensor, *2006 IEEE Conference on Cybernetics and Intelligent Systems*, 7-9.
- [45] Banerjee, T., Keller, J. M., Skubic, M. ve Stone, E. (2014). Day or Night Activity Recognition From Video Using Fuzzy Clustering Techniques, *IEEE Transactions on Fuzzy Systems*, cilt 22, pp. 483-493, June.
- [46] Zhu, S., Xu, J., Guo, H., Liu, Q., Wu, S. ve Wang., H. (2018). Indoor Human Activity Recognition Based on Ambient Radar with Signal Processing and Machine Learning, *2018 IEEE International Conference on Communications (ICC)*.
- [47] Kao, T.-P., Lin, C.-W. ve Wang, J.-S. (2009). Development of a portable activity detector for daily activity recognition, *2009 IEEE International Symposium on Industrial Electronics*.
- [48] Tarca, A. L., Carey, V. J., Chen, X.-w., Romero, R. ve Drăghici, S. (2007). Machine Learning and Its Applications to Biology, *PLoS Comput Biol* 3(6): e116.
- [49] Chapelle, O., Scholkopf, B. ve Zien, E. A. (2009). Semi-Supervised Learning (Chapelle, O. et al., Eds.; 2006) [Book reviews], *IEEE Transactions on Neural Networks*, cilt 20, no. 3, pp. 542-542.
- [50] Moghaddam, B. ve Yang, M.-H. (2000). Gender classification with support vector machines, *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition (Cat. No. PR00580)*, 2000.
- [51] Wang, L., (2005) Support Vector Machines: Theory and Applications, Netherlands.
- [52] BİLGİN, M. (2018). 5.3. K-En Yakın Komşu, *Makine Öğrenmesi*, PAPATYA YAYINCILIK EĞİTİM EĞİTİM BİLGİSAYAR SİS.SAN. VE TİC. A. Ş., pp. 77-78-79.
- [53] Soman, K., Loganathan, R. ve Ajay, V. (2011). Supervised Automatic Learning - A probabilistic

- Framework, *Machine Learning with SVM and Other Kernel Methods*, New Delhi, pp. 27-28.
- [54] Bilgin, M. (2018). Topluluk Öğrenme Yöntemleri ve Sınıflandırıcıların Performans Ölçümü, *Makine Öğrenmesi*, PAPATYA YAYINCILIK EĞİTİM EĞİTİM BİLGİSAYAR SİS.SAN. VE TİC. A. Ş., p. 135.
- [55] Ordóñez, F. J. ve Roggen, D. (2016). Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition, *Sensors*, cilt 16, no. 1.
- [56] Witten, I. H., Frank, E., Hall, M. A. ve C. J. P. ., *Data Mining: Practical Machine Learning Tools and Techniques*, Cambridge, MA 02139: Elsevier, 2017;2011;2005;2000.
- [57] Abu Alsheikh, M., Selim, A., Niyato, D., Doyle, L., Lin, S., & Tan, H. P. (2016). Deep activity recognition models with triaxial accelerometers. In *AAAI Conference on Artificial Intelligence: Workshop on Artificial Intelligence Applied to Assistive Technologies and Smart Environments* (Vol. WS-16-01 - WS-16-15, pp. 8-13). [WS-16-01] (AAAI Workshop - Technical Report; Vol. WS-16-01 - WS-16-15). Pheonix, United States: AI Access Foundation.
- [58] Ravi, D. , Wong, C., Lo, B., Yang, G.-Z. (2016). Deep learning for human activity recognition: A resource efficient implementation on low-power devices. *2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*, San Francisco, CA, 2016, pp. 71-76. doi: 10.1109/BSN.2016.7516235
- [59] Zhu, W., Lan, C., Xing, J., Zeng, W., Li, Y., Shen, L., Xie, X. (2016). Co-Occurrence Feature Learning for Skeleton Based Action Recognition Using Regularized Deep LSTM Networks, *Thirtieth AAAI Conference on Artificial Intelligence*.
- [60] Kennedy, J. and Eberhart, R. (1995) Particle Swarm Optimization. *Proceedings of the IEEE International Conference on Neural Networks*, 4, 1942-1948. <http://dx.doi.org/10.1109/ICNN.1995.488968>
- [61] Özsağlam, M. Y., ÇUNKAŞ, M. (2008). Optimizasyon Problemlerinin Çözümü için Parçaçık Sürü Optimizasyonu Algoritması, *Politeknik Dergisi*, cilt 11, no. 4, pp. 299-305.
- [62] Karaboğa, D. (2011). *YAPAY ZEKA OPTİMİZASYON ALGORİTMALARI*, NOBEL YAYIN DAĞITIM TİC. LTD. STİ., 2011.
- [63] Kaya, Y., Uya, M., Tekin, R. ve Yıldırım, S. (2014). 1D-local binary pattern based feature extraction for classification of epileptic EEG signals, *Applied Mathematics and Computation*, Cilt %1 / %2243,, pp. 209-219.
- [64] Ojala, T., Pietikäinen, M. ve Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions, *Pattern Recognition*, cilt 29, no. 1, pp. 51- 59.
- [65] Güner, h., Alçin, Ö. F. ve Şengür., A. Automatic digital modulation classification using extreme learning machine with local binary pattern histogram features, *Measurement*, cilt 145, no. 0263-2241, pp. 214 - 225.
- [66] Rong, H., Huang, G. ve Ong, Y. (2008). Extreme learning machine for multi-categories classification applications, *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, Hong Kong.
- [67] Huang, G.-B., Zhu, Q.-Y. ve Siew., C.-K. (2006). Extreme learning machine: Theory and applications, *Neurocomputing*, cilt 70, no. 1-3, pp. 489-501.
- [68] Hecht-Nielsen, R. (1988). Neurocomputing: picking the human brain, *IEEE Spectrum*, cilt 25, no. 3, pp. 36-41.
- [69] Basheer, I. ve Hajmeer., M. (2000). Artificial neural networks: fundamentals, computing, design, and application, *Journal of Microbiological Methods*, cilt 43, no. 1, pp. 3-31.
- [70] Moayedi, H. ve Rezaei., A. (2019). An artificial neural network approach for under-reamed piles subjected to uplift forces in dry sand, *Neural Computing and Applications*, cilt 31, no. 2, pp. 327--

336.

- [71] Montgomery, D. C. (2009). Introduction to statistical quality control, *Hoboken, NJ: Wiley*.
- [72] Anguita, D., Ghio, A., Oneto, L., Parra, X. and Reyes-Ortiz, Jorge L. (2012). A Public Domain Dataset for Human Activity Recognition Using Smartphones., *21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, Bruges, Belgium.
- [73] Fang, S. H., Liang, Y. C. ve Chiu, K. M. (2012). Developing a mobile phone-based fall detection system on android platform, *Hong Kong: Institute of Electrical and Electronics Engineers*.
- [74] Wang, M., Huang, C. ve Lin, H. (2006). An Intelligent Surveillance System Based on an Omnidirectional Vision Sensor, *2006 IEEE Conference on Cybernetics and Intelligent Systems*, 7-9



ÖZGEÇMİŞ

Büşran AŞICI

KİŞİSEL BİLGİLER

Doğum Yeri : Malatya
Doğum Yılı : 1992
Uyruğu : T.C.
Adres : Hidayet Mah. Gurur Sok. No:23 Battalgazi / MALATYA
E-posta : busran44@gmail.com
Yabancı Diller : İngilizce (YÖKDİL: 71,25; YDS:61,25)

EĞİTİM BİLGİLERİ

Lisans : Gaziantep Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 2016
Lise : Beydağı Abdüllkadir Eriş Anadolu Lisesi, Malatya, 2010

ARAŞTIRMA DENEYİMİ

✓ **Programlama Dilleri** : MATLAB, Python, Android, C, C++

AKADEMİK FAALİYETLER

Uluslararası Bildiriler:

1. Büşran A. (2019)., “Detection of Fall Event with Extreme Learning Machine and One Dimensional Local Binary Pattern”, Sözlü Sunum, 3. *ULUSAL – 1.ULUSLARARASI BİLİŞİM VE YAZILIM MÜHENDİSLİĞİ KONFERANSI*, Türkiye Bilişim Derneği ve IEEE, Bilgi Teknolojileri ve İletişim Kurumu
2. Büşran A. (2019)., “PERFORMANCE ASSESSMENT OF MACHINE LEARNING AND DEEP LEARNING TECHNIQUES IN HUMAN ACTIVITY RECOGNITION”, Sözlü Sunum, *International Engineering and Natural Sciences Conference (IENSC) 2019*, Dicle Üniversitesi

Ulusal Bildiriler:

3. “İnsan Hareket Tanınması için Parçacık Sürü Optimizasyonu Tabanlı Topluluk Sınıflandırıcı Yöntemi” Fırat Üniversitesi Mühendislik Bilimleri Dergisi