



**BİLEĞE GİYİLEN AKILLI TELEFONUN
İVMEÖLÇER VERİLERİNİ KULLANARAK
AKTİVİTE TANIMA**

Ömer OKUCU

**Yüksek Lisans Tezi
Bilgisayar Mühendisliği Anabilim Dalı
Yrd. Doç. Dr. Levent BAYINDIR
2017**

Her hakkı saklıdır

**ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**BİLEĞE GİYİLEN AKILLI TELEFONUN İVMEÖLÇER
VERİLERİNİ KULLANARAK AKTİVİTE TANIMA**

Ömer OKUCU

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ERZURUM

2017

Her hakkı saklıdır



T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ ONAY FORMU



**BİLEĞE GİYİLEN AKILLI TELEFONUN İVMEÖLÇER VERİLERİNİ KULLANARAK
AKTİVİTE TANIM**

Yrd. Doç. Dr. Levent BAYINDIR danışmanlığında, Ömer OKUCU tarafından hazırlanan bu çalışma, 19/07/2017 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı'nda Yüksek Lisans tezi olarak oybirliği / oy çokluğu (.../...) ile kabul edilmiştir.

Başkan: Yrd. Doç. Dr. Levent BAYINDIR

İmza : 

Üye : Yrd. Doç. Dr. Barış ÖZYER

İmza : 

Üye : Yrd. Doç. Dr. Nur Hüseyin KAPLAN

İmza : 

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu'nun 03.08/2017 tarih ve 31.../16..... nolu kararı ile onaylanmıştır.



Prof. Dr. Cavit KAZAZ
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZET

Yüksek Lisans Tezi

BİLEĞE GİYİLEN AKILLI TELEFONUN İVMEÖLÇER VERİLERİNİ KULLANARAK AKTİVİTE TANIMA

Ömer OKUCU

Atatürk Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Levent BAYINDIR

İnsanların gündelik hayatta yapmış olduğu aktiviteleri ve hareketleri hakkında doğru bilgileri elde etme ihtiyacı gün geçtikçe artmaktadır. Bu anlamda tıbbi, askeri, güvenlik vb. alanlarda aktivite tanıma ile ilgili çeşitli çalışmalar yapılmaktadır. Bu tez çalışmasında akıllı telefonlarda bulunan ivmeölçer algılayıcısından elde edilen ivme değerleri kullanarak aktivite tanıma gerçekleştirilmiştir. Bu amaçla geliştirilen cep telefonu uygulaması kullanılarak iki farklı telefon pozisyonu (pantolon cebinde ve bilekte) ve dokuz farklı aktivite (oturma ayakta durma, koşma, uzanma, yemek yeme, merdiven çıkma, merdiven inme, araba sürme, yürüme) için iki adet veri seti oluşturulmuştur. Elde edilen ham veriler işlenerek yirmi iki öznitelikli (ortalama, standart sapma, korelasyon vb.) veri setine dönüştürülmüş ve ardından dört farklı sınıflandırma yöntemi (k-en yakın komşu, Nâive Bayes, Rastgele Orman ve Destek Vektörü Makineleri) aracılığıyla aktivite sınıflandırması gerçekleştirilmiştir. Yöntemlerin uygulanması sonucu oluşan doğruluk yüzdeleri, farklı parametreler ile incelenmiş ve bulgular üç farklı başlık altında paylaşılmıştır. Bu bulgular arasında en dikkat çekici olan, cep telefonu pozisyonunun elde edilen doğruluk yüzdelerini önemli miktarda etkilemesidir. Bilekliğe taşınarak oluşturulan veri setinden elde edilen doğruluk yüzdesinin pantolon cebinde taşınarak oluşturulan veri setinden elde edilen doğruluk yüzdesinden belirgin şekilde fazla olduğu ve bunun bilek bölgesindeki hareket yoğunluğunun aktivite tanıma işlemi için ekstra bilgi sunmasından kaynaklandığı gözlemlenmiştir.

2017, 79 sayfa

Anahtar Kelimeler: Aktivite tanıma, ivmeölçer, makine öğrenmesi, yaygın bilişim, sınıflandırma

ABSTRACT

MS Thesis

ACTIVITY RECOGNITION USING ACCELEROMETER DATA OF WRIST-WORN SMART PHONE

Ömer OKUCU

Atatürk University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Levent BAYINDIR

The need to get the exact information about the activities and movements of the people in everyday life has been increasing day by day. Various studies have been made on activity recognition in the fields such as medical, military, security and etc. for this purpose. In this thesis, activity recognition has been conducted by using the acceleration values obtained from the accelerometer sensor at the smartphones. By using a mobile phone application developed for this purpose, two data sets were created for two different phone positions (in the pocket of the pants and at the wrist) and nine different activities (sitting, standing, running, lying, eating, going up stairs, going down stairs, driving car, walking). The obtained raw data were processed and transformed into a data set with twenty-two features (mean, standard deviation, correlation, etc.) and then activities were classified by using four different classification methods (k-nearest neighbors, Naïve Bayes, Random Forest, and Support Vector Machines). The accuracy percentages, that were obtained by applying the methods, are examined with various parameters and the findings were written under three headings. The most striking one among these findings is that the position of the mobile phone significantly affects the accuracy percentages obtained. It is observed that the accuracy percentage obtained from the data set created by carrying the smartphone at the wristband is significantly greater than the percentage of accuracy obtained from the data set created by carrying in the pocket of the pants. It shows that the motion intensity in the wrist region provides extra information for activity recognition.

2017, 79 pages

Keywords: Activity recognition, accelerometer, machine learning, pervasive computing, classification

TEŐEKKÜR

Bu tezin oluŐturulmasında kıymetli gürüŐleri ile beni yönlendiren ve her zaman tecrübesinden faydalandığım deđerli hocam Sayın Yrd. Doç. Dr. Levent BAYINDIR başta olmak üzere,

ÇalıŐmam boyunca yanımda olan ve her türlüđü desteđi sađlayan yöneticilerim Nabi AYDIN ve Fikret AKBAŐ'a, arkadaşlarım IŐıl KARABEYLİ ve Tamer YILDIZ'a,

Bu süreçte manevi desteklerini sürekli yanımda hissettiđim dualarını hiç esirgemeyen annem Gülmelek OKUCU'ya, kız kardeşlerim Nurseda ve Elif'e, engin tecrübesiyle yaşamıma deđer katan babam Őakir OKUCU'ya,

Desteđini ve güvenini hiç esirgemeyen kıymetli eŐim Fatma OKUCU'ya, biricik kızım Elif Zümra'ma sonsuz teşekkür ederim.

Ömer OKUCU

Temmuz, 2017

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ.....	10
2.1. Aktivite	10
2.1.1. Birleşik aktivite (Composite Activities)	11
2.1.2. Eş zamanlı aktivite (Concurrent Activities).....	12
2.1.3. Sıralı aktivite (Sequential Activities).....	12
2.1.4. Bölünmüş aktivite (Interleaved Activities).....	13
2.2. Aktivite Tanıma	14
2.3. Aktivite Tanıma Süreci	15
2.3.1. Ön İşleme	15
2.3.2. Bölütleme	16
2.3.3. Öznitelik çıkarma.....	17
2.3.4. Öznitelik seçme.....	17
2.3.5. Sınıflandırma.....	18
2.4. Aktivite Tanıma Sistemlerinin Uygulama Alanları	19
2.4.1. Çevresel yardımcı yaşam uygulamaları.....	19
2.4.2. Sağlık izleme uygulamaları.....	20
2.4.3. Güvenlik ve gözetim uygulamaları	22
2.4.4. Tele-İmmersion Uygulamaları	24
2.5. Aktivite Tanıma Sistemleri ve Yaklaşımları.....	25
2.5.1. Aktivite Tanıma İçin Görsel Sistemler	25
2.5.2. Aktivite Tanıma İçin Görsel Olmayan Sistemler.....	30
2.5.3. Aktivite Tanıma Yaklaşımları İçin Çok Modlu Sistemler	32

2.6. Algılayıcılar	35
2.6.1. İvmeölçer	36
2.6.2. Jiroskop (Gyro/Gyroscope).....	37
2.6.3. Barometre (Barometer)	38
2.6.4. Pusula (Magnetic Sesor)	39
2.6.5. Işık Algılayıcısı	40
3. MATERYAL ve YÖNTEM	41
3.1. Aktivite Seçimi	41
3.2. Veri Toplama	42
3.3. Öznitelik Çıkarma.....	48
3.3.1. Ortalama.....	49
3.3.2. Ortalama Büyüklük.....	49
3.3.3. En Küçük Değer.....	49
3.3.4. En Büyük Değer.....	50
3.3.5. Standart Sapma	50
3.3.6. Mutlak Ortalama Fark.....	50
3.3.7. Zero Cross	51
3.3.8. Korelasyon	51
3.4. Verileri Sınıflandırmada Kullanılan Yöntemler	52
3.4.1. K-en yakın komşu	53
3.4.2. Nâive bayes (NB).....	55
3.4.3. Rastgele orman.....	57
3.4.4. Destek vektör makineleri	59
3.5. Performans Ölçütleri.....	62
3.5.1. Doğruluk (Accuracy)	64
3.5.2. Kesinlik (Precision).....	64
3.5.3. Duyarlılık (Recall)	64
3.5.4. F-Ölçütü (F-Measure)	65
4. ARAŞTIRMA BULGULARI.....	66
4.1. Genel Sınıflandırma Performansı	68
4.2. Erkek ve Kadın Farkının İncelenmesi.....	70
4.3. Cep Telefonun Taşınma Pozisyonunun Etkisi	73

5. SONUÇ ve ÖNERİLER	77
KAYNAKLAR	79
ÖZGEÇMİŞ	80



SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

E_{Ap}	Eğitim Veri Setindeki Sinyal Gücü
T_{Ap}	Test Veri Setindeki Sinyal Gücü
\oplus	İkili özel veya İşlemi
\sqcap	İkili ve İşlemi
AC	Alternatif Akım
ε	Epsilon
H	Yardımcı Fonksiyon
Hz	Hertz
mA	Mili Amper
N	Erişim Noktası Sayısı
ω	Benzerlik Fonksiyonunda Kullanılan Eşik Değer
α	Benzer Erişim Noktası Sayısının Katsayısı
β	Benzer Olmayan Erişim Noktası Sayısının Katsayısı
δ	Sinyal Gücünün Değerine Göre 1-0 Sonucu Veren Fonksiyon

Kısaltmalar

2D	2 Boyutlu
3D	3 Boyutlu
AAL	Çevresel Yardımlı Yaşam
AR	Aktivite Tanıma
CARM	İnsan Aktivitesini Tanımlama
GSM	Mobil İletişim için Küresel Sistem
HMM	Hidden Markov Model
HRI	İnsan Robot Etkileşimi
ITMI	Entegre Zaman Hareketi

ITMI	Entegre Zaman Hareketi Görüntüleri
KKA	Kablosuz Algılayıcı Ağlar
kNN	En Yakın Komşu
kNN	K-En Yakın Komşu
LBE	Öğrenme Yaklaşımı
MDS	Çok Boyutlu Ölçeklendirme
NB	Näive Bayes
NB	Näive Bayes
PEL	Olasılıksal Olay Mantığı
RFID	Radyo Frekansı ile Tanımlama
RO	Rastgele Orman
RO	Rastgele Orman Yöntemi
SAIL	Akıllı Destekli Yaşam
SMS	Kısa Mesaj Hizmeti
SVM	Destek Vektör Makinası
VSIP	Video Gözetim Platformu
WSN	Kablosuz Algılayıcı Ağ
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 1.1. IBM firmasının ürettiği Simon tarihte ilk akıllı telefon olarak bilinir.....	2
Şekil 1.2. Bilinen ilk giyilebilir cihaz ayakkabı tabanlı zamanlama cihazıdır.....	4
Şekil 1.3. İntel'in geliştirdiği sezgisel giysi.....	5
Şekil 1.4. Geleneksel giyilebilir cihazların gündelik hayatta yaygın olarak kullanılması çok zordur	6
Şekil 2.1. Hayatımızda sürekli yapmış olduğumuz yürüme, koşma, yüzme vb. birçok hareket aktiviteye örnek gösterilebilir	10
Şekil 2.2. Yürüme, satın alma, yemek yeme tek başına düşük seviyeli aktivite olurken bunlar birleştiğinde öğle yemeği birleşik aktivitesi olmaktadır.....	11
Şekil 2.3. Zaman aralığı olarak t1-t2 arasında TV izlerken aynı anda telefon konuşması eş zamanlı aktiviteye örnektir.....	12
Şekil 2.4. Kitap okuma sıralı aktivite örneğini kitabı alma, okuma ve yerine bırakma oluşturur.....	13
Şekil 2.5. Yemek yapıyorken lavaboya gidip tekrar yemek yapma aktivitesine devam etme durumu bölünmüş aktiviteye örnektir	13
Şekil 2.6. Oturma, ayakta durma, yürüme, koşma vb. aktiviteler akıllı telefon aracılığıyla çeşitli algılayıcılar kullanılarak tanımlanabilir	14
Şekil 2.7. Aktivite tanıma işlemi süreci ön işleme, bölütleme, öznelik çıkarma ve öznelik seçmeden oluşur.....	15
Şekil 2.8. Oturma ve ayakta durma verilerine mean, düşük ve yüksek geçiş filtrelerinin uygulanmış hali arasındaki farklar gösterilmiştir.....	16
Şekil 2.9. Yürüme ve merdiven çıkma aktivitelerinin bölütlenmiş hali gösterilmiştir.....	17
Şekil 2.10 Çeşitli fiziksel aktiviteler yöntemler aracılığıyla sınıflandırılabilir.....	18
Şekil 2.11. Akıllı ev sistemleri evlerde kullanılan cihazları otomatik ve uzaktan yönetilebilir hale getirmiştir.....	20
Şekil 2.12. Uzaktan kontrol ve sağlık izleme uygulamaları hasta takibi açısından verimli sonuçlar elde etmektedir	21

Şekil 2.13. İnsan faaliyetlerinin operatörler tarafından sürekli izlenmesi oldukça zor ve maliyetlidir.....	23
Şekil 2.14. Konferans odasından uzak bir odaya doğru gerçekleşen tele- immersion mimarisinin aşamaları gösterilmektedir	25
Şekil 2.15. Algılayıcılar; ivme, nem, basınç, ses, kuvvet, Isı, uzaklık, elektrik ve pH gibi değerleri elektrik sinyallerine dönüştürür.....	36
Şekil 2.16. Bir cep telefonunda bulunan ivmeölçerin eksenleri x, y ve z'den oluşmaktadır	37
Şekil 2.17. Jiroskoplar yön ölçümü veya ayarlanmasında kullanılırlar	38
Şekil 2.18. Teknolojinin gelişmesiyle birlikte dijital barometreler sıklıkla kullanılmaya başlanmıştır	39
Şekil 2.19. Dünya manyetik alanına göre x,y,z değerleri gösterilmiştir	39
Şekil 2.20. Işık algılayıcıları sayesinde gün ışığına göre aydınlatma işlemi gerçekleştiren sokak aydınlatma aletleri	40
Şekil 3.1. Geliştirmiş olduğumuz uygulamanın ana ekran görüntüsü	43
Şekil 3.2. Ana ekranda bulunan açılır menünün içerisinde kullanacağımız bütün aktiviteler bulunmaktadır	44
Şekil 3.3. Veriler varsayılan klasör içerisinde a ve m şeklinde dosyalar oluşturmakta	45
Şekil 3.4. Pantolon cebinde ve bileğe takılı telefonların taşıma şekli gösterilmektedir	47
Şekil 3.5. Zero Cross sıfır noktasında istenen işlemin tetiklenmesi yapılır.....	51
Şekil 3.6. Korelasyon değişkenler arası ilişki türleri gösterilmiştir.....	52
Şekil 3.7. K-en yakın komşu (kNN) yöntemi (Anonymous 2012)	54
Şekil 3.8. K-en yakın komşu yöntemi akış diyagramı	55
Şekil 3.9. Nâive Bayes sınıflandırıcısı oldukça başarılı bir sınıflandırıcıdır	55
Şekil 3.10. Nâive Bayes yöntemi kullanılarak Doğrusal A'nın Doğrusal olmayan B probleminden daha iyi sonuç alacağı görülmektedir	56
Şekil 3.11. Ağaç topluluğu oluşturulurken; eğitim veri setindeki N adet örnek sayısı N sayıda durumla rastgele olarak yer değiştirerek ağaç oluşturmaktadır.....	58

Şekil 3.12. İki çizgiye paralel sınır çizilip ortak sınır çizgisi iki paralel çizgisi arasında üretilir.....	60
Şekil 3.13. İki çizgi boyunca aşırı düzlemin tek yönlü olması imkansızdır	62
Şekil 4.1. Ömer (Sol) ve Işıl'a (sağ) ait yürüme aktivitesine ait verilerin öznitelik değerleri birbirlerine çok yakın gözükmemektedir	73
Şekil 4.2. Koşma aktivitesi yapılırken yürüme aktivitesine göre kollar daha çok açılı olarak hareket eder.....	76



ÇİZELGELER DİZİNİ

Çizelge 1.2. Akıllı telefonların kullanım süreleri her geçen gün katlanarak artmaktadır	7
Çizelge 3.1. Geliştirmiş olduğumuz uygulama aracılığıyla kaydedilen ham verilerden örnekler	46
Çizelge 3.2. Veri seti oluşturan kişilerin karakteristik özellikleri	47
Çizelge 3.3. Ham veriye öznitelikler uygulandıktan sonra oluşan öznitelikli veri seti.....	48
Çizelge 3.4. Karışıklık matrisi genel formu.....	63
Çizelge 4.1. Sınıflandırma yöntemlerinde kullanılan parametrelerin varsayılan değerleri	67
Çizelge 4.2. Bileklikte oluşturulan altı kişiye ait veri setlerine uygulanan aktivite tanıma yöntemlerinin doğru tahmin yüzdeleri.....	68
Çizelge 4.3. Işıl'ın bileğe takılı cep telefonu ile topladığı veri seti sonuçlarına göre en iyi yöntem olan RO'nın karışıklık matrisi gösterilmiştir. Birbirleriyle en çok karıştırılan aktivitelerin sayısı kutu içerisinde gösterilmiştir	1
Çizelge 4.4. Üretilen öznitelik veri setinin bir kısmı gösterilmektedir. Öznitelik değerleri yerden tasarruf etmek amacıyla yuvarlanmıştır. Veri sütununda karşılık gelen özniteliklerin detaylı açıklamaları bölüm 3.3'de detaylı bir şekilde verilmiştir.	71
Çizelge 4.5. RO yöntemi kullanılarak veri setimizde işaretlemiş olduğumuz erkek ve kadınların aktivite bazında tahmin oranları	72
Çizelge 4.6. Sınıflandırma yöntemleri uygulandıktan sonra Ömer ve Fatma'nın bilek ve cep sonuçları	74
Çizelge 4.7. RO yöntemi kullanılarak aktivite bazlı Ömer ve Fatma'ya ait bileğe takılı telefon ve cepte bulunan telefon verilerinin karşılaştırılması.....	75

1. GİRİŞ

Dünya, 1990'lı yıllardaki İnternet ve 2000'li yıllardaki mobil İnternet çıkışlarından sonra teknolojik gelişmelerin etkisiyle üçüncü en popüler bir trende doğru ilerlemektedir. Yaygın bilişim ve Nesnelerin İnterneti olarak adlandırılan geleceğin bu dünyasında fiziksel dünyadaki nesnelerin insanlarla ve birbiriyle kablosuz ağlar üzerinden iletişim kurması söz konusudur. Her zaman, her yerde ve sadece insanların değil her nesnenin çevrimiçi olduğu bir dünya öngörülmektedir.

Yaygın Bilişim

Yaygın bilişim ilk olarak 1991 yılında Xerox Palo Alto araştırma merkezindeki araştırmacı Mark Weiser tarafından ortaya atılmıştır. Weiser'e göre yaygın bilişim, her zaman her yerde var olan ve arka planda sessizce işleyen bilişimi ifade etmektedir. Günlük yaşamımızda çevremizde bulunan fiziksel nesnelere gömülü mikroişlemciler, algılayıcılar ve her nesnenin kablosuz üzerinden algıladığı bilginin aktarıldığı "akıllı çevre" içinde olacağımız böyle bir dünya da bilişim geleneksel PC'lerin içinde değil her objeye gömülü olarak ve doğal insan-bilgisayar ara yüzleriyle arka planda gerçekleşebilecektir. Görünmezlik, bağlam farkındalık ve yaygınlık olmak üzere yaygın bilişimin üç temel özeliği vardır. Yapmış olduğumuz çalışmada üzerine sıkça değineceğimiz akıllı cihazlar ve giyilebilir cihazlar yaygın bilişimin birçok alanından yalnızca iki tanesidir.

• Akıllı Cihazlar

Akıllı cihazlar bir PDA veya bilgisayarın özelliklerine sahip, kendine özgü ve ileri düzey bir işletim sistemini kullanan mobil cihazları tanımlamak için kullanılan bir tanımdır. Akıllı telefonlar işletim sistemi olarak mobil işletim sistemini kullanır. İçerisinde bulundurduğu işletim sistemine göre birçok uygulama çalıştırır.

İlk akıllı telefon IBM'in sunmuş olduđu Simon olarak kabul edilir. Amerika'da bulunan IBM şirketi tarafından geliştirilen Simon, bazı özellikleri ile cep telefonu, bazı özellikleriyle bilgisayar, bazı özellikleriyle çağrı cihazı ve bazı özellikleriyle faks makinasını anımsatır. Simon'da aynı zamanda hesap makinesi, fihrist, takvim, çeşitli oyun vb. uygulamalar da bulunuyordu.



Şekil 1.1. IBM firmasının ürettiği Simon tarihte ilk akıllı telefon olarak bilinir (Anonymous 1992)

Simon'dan hemen sonra Nokia, Ericson ve PALM bu pazarda yerini aldılar. Oluşan rekabet ortamı ve gelişen teknolojiyle birlikte akıllı telefonlar her yeni günde yeni özellikleriyle karşımıza çıktılar. 2007 yılında akıllı telefonların gelişmesi sürecinde bir milat olarak kabul edilen ilk iPhone modeli piyasaya sürüldü. iPhone genel anlamda ilk dokunmatik ekrana sahip telefondur. Kendinden sonra piyasaya sürülen diğer tüm akıllı telefonlar için örnek olma özelliğini barındırmaktadır. iPhone'dan hemen sonra HTC ve Samsung markaları akıllı telefonların yaygınlaşma sürecini hızlandırdı. Akıllı telefonların birbirlerinden ayır edici en önemli özelliği olan işletim sistemleridir aşağıda verilmiştir.

Android, Kullanılan mobil işletim sistemleri arasında birinci sıradadır. Açık kaynaklı ve Linux tabanlı bir işletim sistemidir. Google geliştiricileri tarafından oluşturulmuş ve aynı firma tarafından piyasaya sürülmüştür. Birçok firma tarafından kullanılmakta ve destek verilmekte olup en yaygın olarak Samsung ve HTC şirketlerinin üretmiş olduğu cihazlarda karşımıza çıkmaktadır.

İOS, Apple firması tarafından geliştirilen ve destek verilen bir işletim sistemidir. Yalnızca Apple firmasının üretmiş olduğu cihazlarda çalışmaktadır. Kapalı kaynaklıdır.


Symbian, dünyanın en fazla ikinci kullanılan işletim sistemidir. Nokia firması tarafından destek verilmekte ve geliştirilmektedir. Son zamanlarında eski popülerliğini tamamen kaybetmiştir. Pazar payını genel olarak android ve ios'a kaptırmıştır.

Windows, Microsoft tarafından üretilmiş olup geliştirilmektedir. Microsoft ve Nokia akıllı cihazlarında kullanılmaktadır.

• **Giyilebilir Cihazlar**

Giyilebilir cihazlar giyebileceğimiz elektronik takı ve elbiselerdir. İnsanların bu teknolojiye ilgisi her geçen gün artmaktadır. Bilgisayardan daha çok ilgi gören bu teknoloji fiziksel aktivitelerin takibi ve tıbbi verilerin izlenmesi gibi işlemlerde bilgisayardan daha verimlidir. Genel olarak, giyilebilir teknoloji haberleşmeye, giyen kişinin anlık bütün bilgilerine erişebilmeye ve içerdiği kayıt sistemine kayıt etmeye imkân sağlamaktadır

Modern anlamda giyilebilir ilk bilgisayar 1955 yılında Edward O. Thorp tarafından tasarlanmıştır. Kısa süre sonra icat edilmiş Şekil 1.2'de gösterilen ayakkabı tabanında zamanlama cihazıdır.



Şekil 1.2. Bilinen ilk giyilebilir cihaz ayakkabı tabanlı zamanlama cihazıdır (Anonymous 1995)

Giyilebilir teknoloji alanında geliştirmeler yapan Mann'ın 1994 yılında icat ettiği giyilebilir kablosuz web kamerası ile kişinin bütün hayatını fotoğraf ve kameraya kaydı ile takip altına alabilmekteydi. Bu şekilde giyilebilir cihazlar günden güne gelişerek boyutları küçülürken işlevleri artı.

Giyilebilir teknolojinin gelişmesinde etkili unsur, hastaların gündelik hayatta yapmış oldukları aktivitelerini takip edebildikleri sağlık uygulamalarıdır. 2008 yılından sonra birçok araştırmacı tarafından kilo vermek için harcanan kaloriyi, yolculukta gidilen kilometreyi ve aktivite çeşitliliğini hesaplayabilen bileklikler tasarlanmıştır.

2013 yılında Samsung Galaxy Gear'i üretti bu anlamda büyük bir atılım gerçekleştirdi. 2014 yılında Android Wear işletim sistemi kamuoyuna duyurulmuş olup aynı senede LG Watch ve Samsung Gear akıllı saatleri belirtilen işletim sistemleri ile kullanıma çıkmıştır. 2015 yılında Apple firmasının üretmiş olduğu yoğun ilgi gören akıllı saati Apple Watch satışa sunulmuştur.

Gelecekte giyilebilir cihazlar kapsamında Intel, Şekil 1.3'te gösterilen Adrenaline Dress adını verdiği sezgisel bir giysi yapmak için Chromat firması ile iş birliği yapmıştır. Giyenin vücut sıcaklığını ve adrenalin ve stres seviyesini ölçebilen bu giysi moda endüstrisi içinde teknolojinin dönüştürücü gücünü özetlemektedir.



Şekil 1.3. Intel'in geliştirdiği sezgisel giysi (Anonymous 2010)

Giyilebilir teknoloji, sağlık ve güvenlik ile bu ve benzeri aletlerin gün geçtikçe yakada iğne, boyunda kolye, gözde gözlük, ayakkabıda tabanlılık, kolda daha gelişmiş saat ve bileklik ve kulakta ileri düzey küpe şeklinde hayatımızın parçası haline gelmesi beklenmektedir. Bu gelişmeler tekstil üretim alanında büyük değişime yol açacağını göstermektedir.

Bilgi teknolojilerindeki hızlı ve bir o kadar yaygın gelişme sayesinde insanların veriye ulaşma yöntemlerinin geliştirilmesi, ulaşılan bu verilerin belirli standartlara tabi tutularak biriktirilmesi ve kullanılabilir bilgilere dönüştürülmesi için yeni fikirler ve görüşler ortaya sunulmuştur.

Bilgi teknolojilerinin getirmiş olduğu bu yeniliklerden biri olan ve popülerliği artarak önem kazanan, insanların ihtiyaç duyduğu doğru ve güvenilir bilgiyi elde etmek, birçok alanda önemli olduğu gibi yaygın bilişimin de önemli konularından biridir.

Yaygın bilişimin önemli çalışma alanlarından biri de insanların gündelik hayatta yapmış olduğu aktiviteleri ve hareketleri hakkında doğru bilgileri elde etmektir. Bu aktivitelerin tanınması tıbbi, askeri, güvenlik ve daha birçok alanda önemlidir. Örneğin, tıbbi alanda son zamanlarda gündemde olan obezitenin önüne geçmek için hazırlanan fiziksel egzersizlerin otomatik olarak takip edilmesi buna örnek gösterilebilir. Bir başka örnek ise, gündelik hayatta belirli zaman ayrılan işlerin çeşitli yöntemler kullanılarak

kategorilere ayrılması ve kategorilere ayrılmış bu aktivitelerin detaylı bir şekilde incelenmesi bu şekilde zaman, iş gücü vb. birçok alanda tasarruf sağlanılabilmektedir.

Aktivite tanıma bilgilerini elde ederken GPS, mikrofon, kamera, pusula, manyetik algılayıcı, ivmeölçer vb. pek çok algılayıcı cihaz kullanılabilir. Bu algılayıcı cihazların bazılarının birlikte kullanılması veya bunlara ek özellik olarak verinin saklanabilmesi, işlenebilmesi ve kullanılabilmesi için ilave araçlara ihtiyaç duyulabilmektedir.



Şekil 1.4. Geleneksel giyilebilir cihazların gündelik hayatta yaygın olarak kullanılması çok zordur (Anonymous 1999)

Geleneksel aktivite tanıma yaklaşımlarında bir veya daha fazla cihazın kullanıcının vücudunun belirli yerlerine yerleştirildiği ve bu şekilde kullanıldığı görülmektedir. Hareket özgürlüğünü kısıtlayan bu yaklaşım gündelik hayatta yaygın kullanımı imkânsız hale getirmekle beraber Şekil 1.4'te görüldüğü gibi görünüm, kullanılabilirlik, taşınabilirlik, maliyet vb. açılarından da dezavantajlara sahiptir. Tüm bu dezavantajları göz önünde bulundurduğumuzda geleneksel aktivite tanıma yaklaşımlarının değişen ve gelişen teknolojilerde birçok yeniliğe ihtiyaç duyduğu görülmektedir.

Bazı aktivitelerin tanımlanması için özel olarak tasarlanmış araçları günlük hayatımızda sürekli yanımızda taşımamızın doğuracağı zorluklardansa zaten yanımızda bulundurmamayı alışkanlık haline getirdiğimiz araçlar daha çok tercih edilir. Araç tercihi için daha pratik ve gündelik hayatımızın parçası haline gelmiş, ihtiyaç duyulabilecek birçok algılayıcıyı içeren, yüksek hesaplama gücüne sahip, küçük boyutlu ve bağıl olarak daha düşük maliyetli olan cep telefonları, bilgisayarlar ve tabletler daha fazla tercih edilmektedir.

Çizelge 1.2. Akıllı telefonların kullanım süreleri her geçen gün katlanarak artmaktadır

Platformlarda Geçirilen Süreler (Saat)				
Platform	Haziran 2014	Haziran 2015	Fark	Fark
PC	128.962.942	122.822.013	-6.140.928	-5%
Akıllı Telefon	14.751.766	31.728.114	16.976.347	115%
Tablet	2.029.789	3.434.429	1.404.640	69%
Diğer	84.259	58.885	-25.374	-30%
Toplam	145.828.757	158.043.441	12.214.685	8%

2014-2015 yılları arasındaki bu platformlarda geçirilen süreler Çizelge 1.1'de gösterilmiştir. Kullanım süresi olarak incelediğimizde 2014 yılından 2015 yılına akıllı telefonlar %115 (kişi başına birden fazla telefon düştüğü anlamına gelir) ve tabletler %69 yükselirken diğer cihazların kullanımı düşmüştür. Bu değişim ve dönüşüm taşınabilir cihazların teknolojik olarak geliştirilmesi ve ilerlemesinden kaynaklanmaktadır. Tüm bu sonuçları diğer yıllarla da karşılaştırdığımızda tablet ve özellikle akıllı telefonların kullanım süreleri her geçen gün artmakta hayatımızda ciddi bir önem kazanmaktadır.

Gün geçtikçe popülaritesi artan bu teknoloji içerisinde birçok özellik barındırmaktadır. Örnek olarak WİFİ, kamera, bluetooth, mikrofon, hoparlör manyetik algılayıcı, GPS, ısı

ve ışık algılayıcıları, ivmeölçer vb. birçok özellik sayılabilir. Bu özelliklerin bazılarının birlikte kullanılmasıyla taşınması oldukça zor büyüklükteki geleneksel cihazların yaptığı işlemleri daha pratik ve daha hızlı bir şekilde gerçekleştirmek mümkündür.

Herkesin bir cep telefonuna sahip olması yanı sıra cep telefonunu gündelik hayatımızda kullanım ve yanında bulundurma oranlarını da detaylı bir şekilde incelememiz gerekmektedir. Böyle bir inceleme gerçekleştirdiğimizde cep telefonların dezavantajları oraya çıkmaktadır. Gündelik hayata baktığımızda sosyal medya, alışveriş, İnternette araştırma, mesajlaşma, telefon görüşmesi vb. tüm işlemler günün büyük bir bölümünü kapsasa da telefonumuzu 24 saat yanımızda bulundurmamız mümkün değildir. Uyku hali, çalışma esnasında masaya bırakılan telefon vb. birçok durumda cep telefonu yanımızda bulunmamasına örnek gösterilebilir. Buna ek olarak akıllı telefonlarda ihtiyaca göre geliştirilen api'ler bulunmaktadır. Örnek olarak gündelik hayatımızda yapmış olduğumuz aktivitelerin kolayca takibini sağlamak amacıyla apiler geliştirilmiş olup birçokumuz bu apileri yaygın olarak kullanmaktayız.

Tüm bu avantaj ve dezavantajlara bakıldığında yenilikçi giyilebilir teknolojilerin daha pratik ve kullanışlı olması muhtemeldir. Gelecekte cep telefonlarının sağlamış olduğu bu imkânların daha küçük kullanılabilir cihazlarda bulunması mümkün olacaktır. Örnek olarak üst tarafta anlatılan Apple Watch, Samsung Gear vb. cihazlar hızlı bir şekilde yaşam alanlarımıza girmektedir. Kola takılı olan akıllı saat cebimizde ya da elimizde taşımış olduğumuz telefondan daha fazla bizimle etkileşim halinde olacağı gibi uyurken, çalışırken vb. birçok aktivitede de bizimle etkileşim halinde olacaktır.

Bu çalışmamızda kola takılı halde bulunan cep telefonu ile aktivite tanıma işlemini gerçekleştirmemizin temel nedeni; şuan yaygın olarak kullanılan akıllı telefonunu kullanırken gelecekte beklediğimiz bu hızlı dönüşüme uyum sağlamak ve yapılan çalışmaların gelecekte giyilebilir teknolojilerin üreteceği tüm cihazlara uygulanabilir olmasıdır.

Cep telefonlarının hayatımızın birçok yerinde yanımızda bulunması aktivite tanıma işleminde gerçek manada katkısı büyük olacaktır. Bu yolla aktivite tanımlama yöntemleri test ve laboratuvar ortamından çıkıp gündelik yaşamımızın içerisine dâhil olmuştur.



2. KAYNAK ÖZETLERİ

2.1. Aktivite

Aktivite, genel olarak vücut hareketlerini açıklamak için kullanılan bir terimdir. Fiziksel aktivite ise gündelik hayatta eklem ve kaslarımızı kullanarak enerji tüketimi ile kalp ve solunum hızını artırırken farklı şiddetlerde yorgunlukla sonuçlanan aktiviteler olarak tanımlanabilir.



Şekil 2.1. Hayatımızda sürekli yapmış olduğumuz yürüme, koşma, yüzmeye vb. birçok hareket aktiviteye örnek gösterilebilir

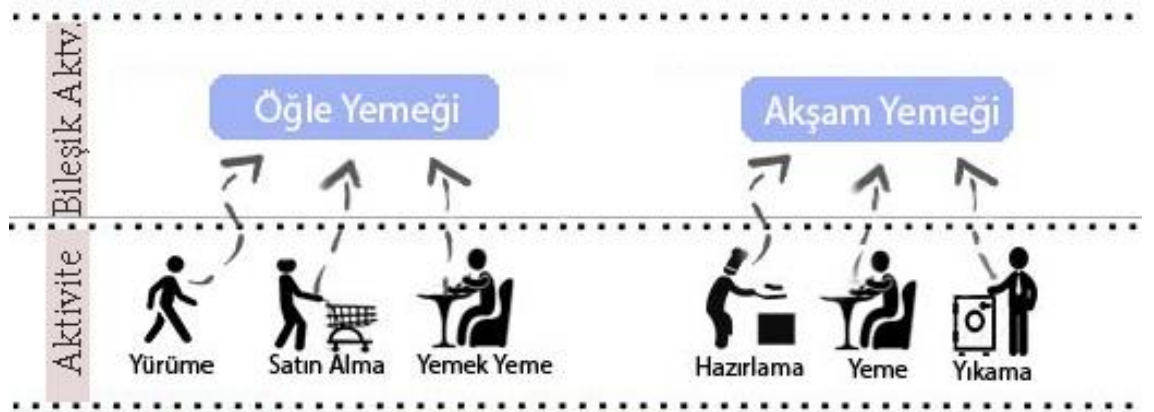
Günlük hayatta gerçekleştirdiğimiz aktiviteleri incelediğimizde kendi içinde çeşitli kategorilere ayrılmıştır. Başlıklar altında incelenen bu kategoriler aşağıda verilmektedir.

- Yürüme
- Koşma
- Sıçrama
- Yüzme
- Bisiklete binme
- Çömelme kalkma
- Kol ve bacak hareketleri
- Baş ve gövde hareketleri

Yukarda belirtilen temel vücut hareketlerinin tümünü ya da bir kısmını içeren Şekil 2.1'de de gösterilen çeşitli spor dalları, dans, egzersiz, oyun ve gün içerisindeki aktiviteler fiziksel aktivite olarak kabul edilebilirler. Bu şekilde alt başlıklar halinde kategorize edilen aktiviteler gruplar halinde de incelenmektedir. Bunlar birleşik aktivite, eş zamanlı aktivite, sıralı aktivite ve bölünmüş aktivitedir.

2.1.1. Birleşik aktivite (Composite Activities)

Geniş anlamda bir aktivitenin yapılabilmesi için işlem süresince yapılan diğer işlemlerin birleştirilerek tek çatı altında isimlendirilmesidir. Aktivite tanımlanırken yüksek seviye aktiviteler ve düşük seviye aktiviteler olarak temel anlamda ikiye ayrılır. Düşük seviye aktiviteler birleşerek yüksek seviyeli aktiviteyi oluşturur. Bu birleşim sonucu oluşan aktiviteye birleşik aktivite denir. Örnek olarak Şekil 2.2'de düşük seviye aktivitelerin yürüme, yemeği alma, yemeği yeme birleşerek öğle yemeği aktivitesini oluşturduğu görülmektedir.



Şekil 2.2. Yürüme, satın alma, yemek yeme tek başına düşük seviyeli aktivite olurken bunlar birleştiğinde öğle yemeği birleşik aktivitesi olmaktadır

2.1.2. Eş zamanlı aktivite (Concurrent Activities)

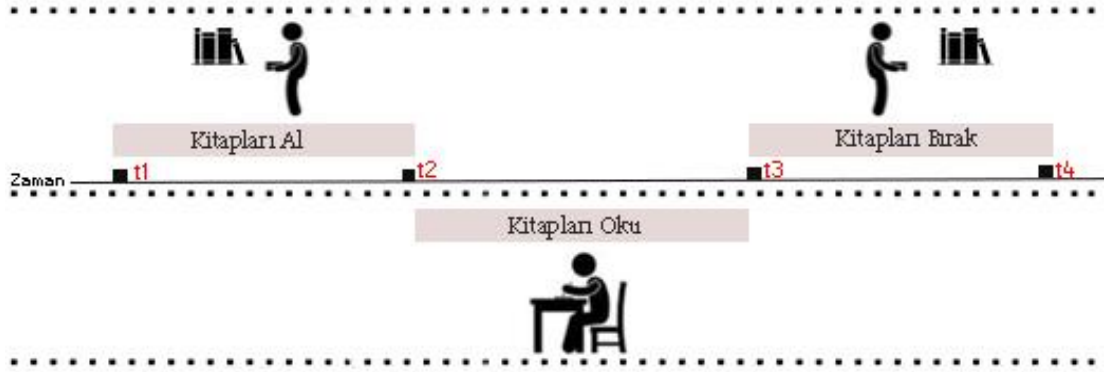
Herhangi bir anda başlamış olan bir aktiviteyi yapmaya devam ediyorken başka aktivitelere de başlanılabılır. Bu durumda devam eden ve yeni başlanılan aktivitelerin aynı anda gerçekleşmesine eş zamanlı aktivite denir. Eş zamanlı aktivitelerde hem yüksek seviyeli hem de düşük seviyeli aktivitelerin aynı anda yapılabildiği görülmektedir. Şekil 2.3’de gösterildiği üzere t1-t3 zaman aralığında televizyon izleme aktivitesi gerçekleştirilmektedir. Bu aktivite devam ederken t2’de telefon konuşma aktivitesi başlıyor. Her iki aktivitenin t2-t3 zaman aralığında aynı anda gerçekleştirilmesi eş zamanlı aktiviteye örnek gösterilebilir.



Şekil 2.3. Zaman aralığı olarak t1-t2 arasında TV izlerken aynı anda telefon konuşması eş zamanlı aktiviteye örnektir

2.1.3. Sıralı aktivite (Sequential Activities)

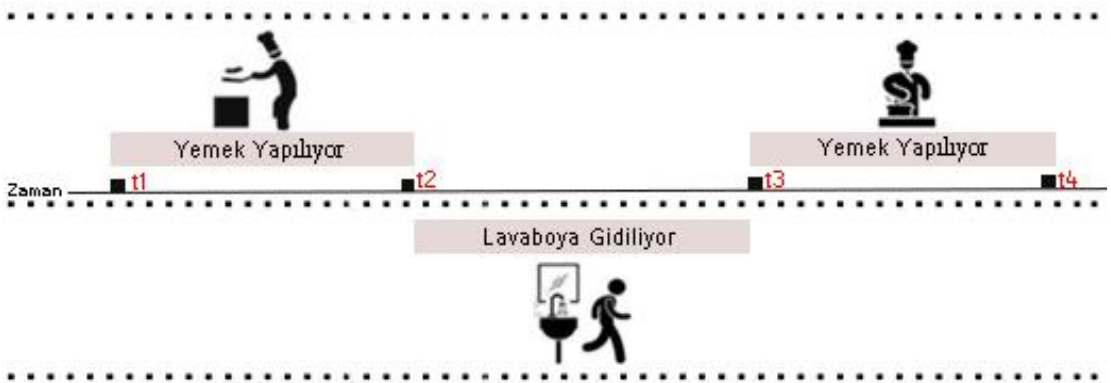
Aynı kişi tarafından herhangi bir zamanda art arda yapılan aktivitelere sıralı aktiviteler denir. Sıralı aktiviteler yüksek seviyeli veya düşük seviyeli aktivitelerden oluşabilir. Şekil 2.4’de gösterildiği gibi t1-t2 zaman aralığında kitapların alınması, t2-t3 zaman aralığında kitapların okunması ve t3-t4 zaman aralığında kitapların yerine konulması sıralı aktiviteye örnektir.



Şekil 2.4. Kitap okuma sıralı aktivite örneğini kitabı alma, okuma ve yerine bırakma oluşturur

2.1.4. Bölünmüş aktivite (İnterleaved Activities)

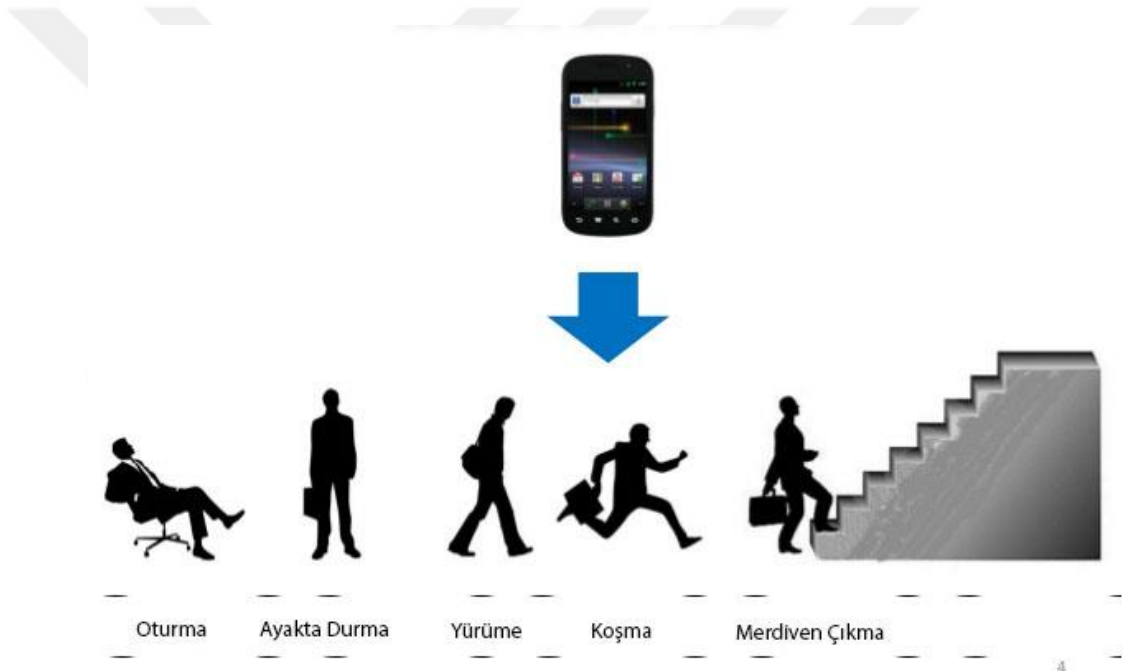
Herhangi bir anda başlamış olan bir aktivite sonlandırılmadan ara verilmesi süratiyle bir başka aktiviteyi gerçekleştirdikten hemen sonra tekrar bir önceki aktiviteye devam etmesi sonucu oluşan aktivite dizinine bölünmüş aktivite denir. Şekil 2.5’de görüldüğü üzere t1-t2 zaman aralığında yemek hazırlarken bu aktiviteye t2-t3 zaman aralığında ara verip gidip tuvalet aktivitesini gerçekleştirdikten sonra tekrar geri dönerek t3-t4 zaman aralığında yemek yapmaya devam edilmesi bölünmüş aktiviteye örnek gösterilebilir.



Şekil 2.5. Yemek yapıyorken lavaboya gidip tekrar yemek yapma aktivitesine devam etme durumu bölünmüş aktiviteye örnektir

2.2. Aktivite Tanıma

Gündelik hayatımızda yapmış olduğumuz aktiviteleri otomatik olarak tanıma, akıllı cihazlar, sağlık izleme uygulamaları ve acil durum servisleri gibi birçok çevresel zekâ uygulaması için önemlidir. Tüm bu uygulamaları sürdürülebilir yapmak için insan aktivitelerinin otomatik olarak algılandığı akıllı yazılımlara ihtiyaç vardır. İnsan davranışlarını anlamak için, toplanan veriler üzerinde makine öğrenmesi yöntemlerini kullanabiliriz.

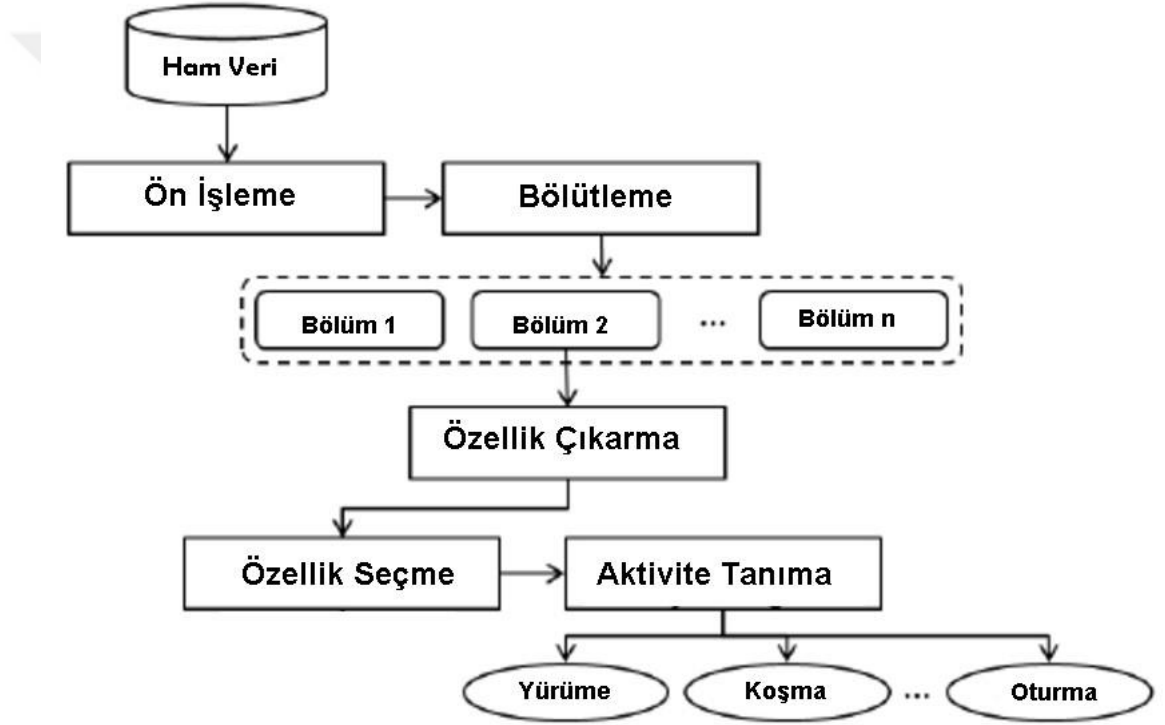


Şekil 2.6. Oturma, ayakta durma, yürüme, koşma vb. aktiviteler akıllı telefon aracılığıyla çeşitli algılayıcılar kullanılarak tanımlanabilir

Aktivite tanıma işleminde genel olarak birçok algılayıcı kullanılmıştır. Bunlara WiFi, kamera, bluetooth, mikروفon, hoparlör manyetik algılayıcı, GPS, ısı ve ışık algılayıcıları, ivmeölçer vb. örnek verilebilir.

2.3. Aktivite Tanıma Süreci

Aktivite tanıma işleminde birçok çözüm önerisi bulunmakla beraber tüm bu çözüm önerilerinin kabul etmiş oldukları genel bir aktivite tanıma süreci vardır (Avcı, et al). Bunlar Şekil 2.7’te gösterildiği gibi ham veriden başlayacak şekilde sırasıyla ön işleme (preprocessing), bölütleme (segmentation), özellik çıkarma (feature extraction), özellik seçme (feature selection) ve sınıflandırma (classification) şeklindedir.

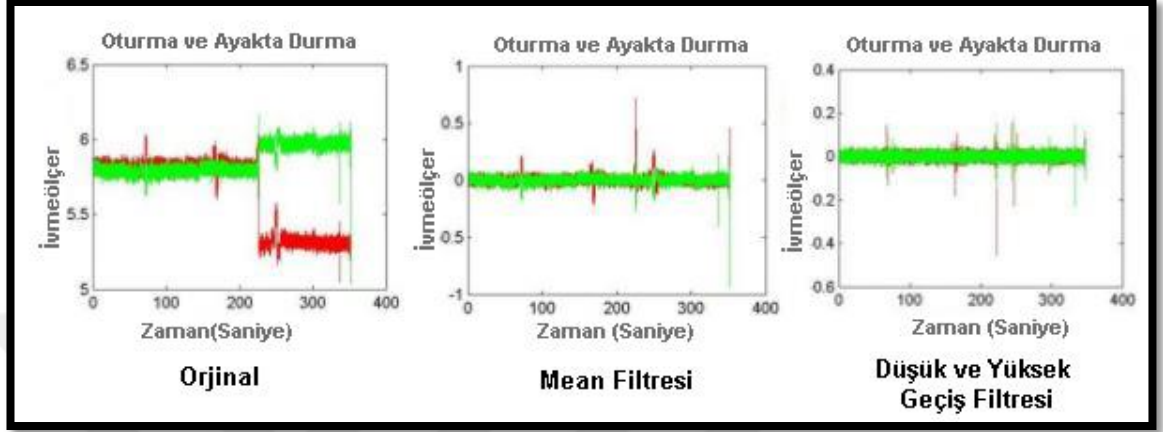


Şekil 2.7. Aktivite tanıma işlemi süreci ön işleme, bölütleme, öznelik çıkarma ve öznelik seçmeden oluşur

2.3.1. Ön işleme

Aktivite tanıma süreci boyunca elde edilen verilerin bilgiye dönüştürülmesi kısmının en önemli bölümlerinden biri ön işleme bölümüdür. Bu adımda ham verileri ulaştığımız bilgi ışığında gerekli ve gereksiz veriler olarak ayırma işlemi gerçekleştirilir (Karantonis *et al.* 2006). Bu ve buna benzer ayırmalardan sonra gereksiz bilgileri

çıkarma işlemi gerçekleştirilirken eş zamanlı olarak kullanılacak verileri daha uygun bir formata dönüştürme işlemi de gerçekleştirilmektedir.

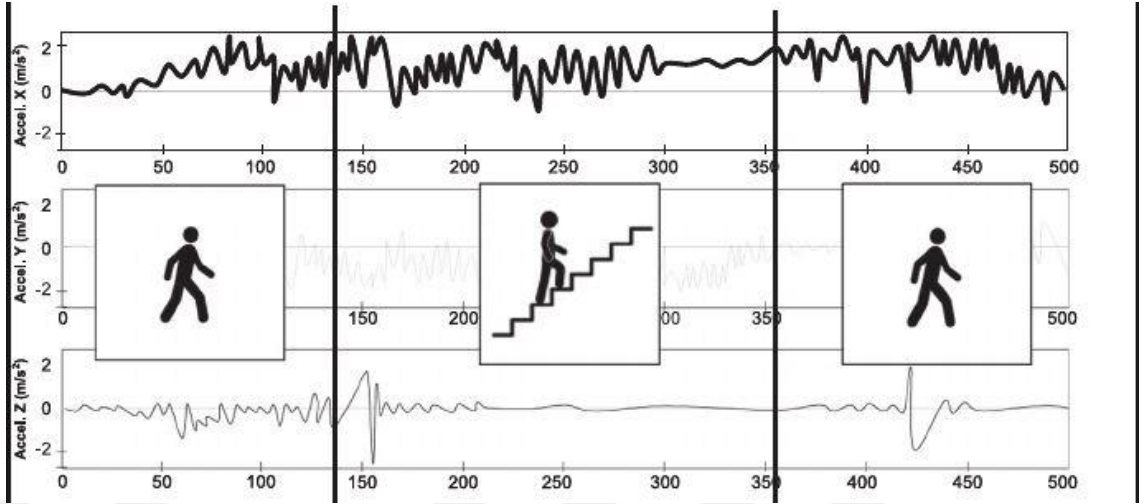


Şekil 2.8. Oturma ve ayakta durma verilerine mean, düşük ve yüksek geçiş filtrelerinin uygulanmış hali arasındaki farklar gösterilmiştir

Genel olarak yapılabilecek olası işlemler gürültünün giderilmesi, sinyalin düzeltilmesi ve eşit olmayan örneklerin eşit duruma getirilmesidir. Gürültünün giderilmesi ile ilgili işlemlerde birçok farklı filtre kullanılabilir. Bu filtreler düşük geçiş, yüksek geçiş, mean, laplacian ve gaussian olarak gösterilebilir (Khan *et al.* 2010). Şekil 2.8’da gösterildiği gibi oturma ve ayakta durma aktivitelerine mean, DG filtresi ve YG filtresi uygulanmış durumları gösterilmektedir.

2.3.2. Bölütleme

Bölütleme bir sinyali değişken ya da sabit boyutlu pencerelere bölerek, sinyalden özniteliklerin çıkarılmasını kolaylaştıran işlemdir. Pencere kaydırma algoritması gibi birçok bölütleme algoritması bulunmaktadır.



Şekil 2.9. Yürüme ve merdiven çıkma aktivitelerinin bölütlenmiş hali gösterilmiştir

Bu algoritmalarından biri Şekil 2.9’da gösterildiği gibi aktiviteye göre bölümlendirir. Bu yöntem uygulandığında aktivitelere göre pencereler oluşturulur bu yolla öznelik çıkarma işlemi daha da kolaylaşır.

2.3.3. Öznelik çıkarma


Öznelikler, bir veri bölümünün farklı karakteristikleri için göstergeler olarak tanımlanabilir. Büyük bir veriden bir dizi öznelik elde ederek benzer veri bölümlerini ayırt etmek suretiyle basit bir vektör elde edilebilir. Öznelikler zaman ve frekans ile hesaplanabilir.

2.3.4. Öznelik seçme

Daha fazla özellik kullanmak her zaman daha iyi sınıflandırma sağlamaz. Birçok öznelik bir arada kullanıldığında aynı türden bilginin fazlalığı, artan hesaplar vb. birçok durumun getirdiği dezavantajla veri kümesinin birbirinden ayırt edici özneliklerini maskeleyebilir. Oluşturulan özneliklerin birlikte kullanılıp test edildikten sonra karmaşıklığı artırıcı etkisi var ise bunu seçerek devre dışı bırakılmalıdır.

2.3.5. Sınıflandırma

Aktivite tanıma işlemindeki son adım sınıflandırmadır. Bu aşama olası tüm gözlemleri kapsayacak şekilde aktiviteleri kategorize eder. Örnek olarak Şekil 2.10'da yürüme ve koşma aktivitesi sınıflandırma yöntemi sonucunda tam olarak ayrıştığı gösterilmektedir.



Şekil 2.10 Çeşitli fiziksel aktiviteler yöntemler aracılığıyla sınıflandırılabilir

Aktivite tanımda en yaygın kullanılan sınıflandırma yöntemleri şunlardır.

- K-en Yakın Komşu Algoritması (KNN)
- Karar Ağacı (DT)
- Destek Vektör Makineleri (SVM)
- Nâive Bayes (NB)
- Gizli Markov Modeli (HMM)
- Rastgele Orman (RF)
- Sınır Ağı (NN)
- Bulanık Mantık (FL)

2.4. Aktivite Tanıma Sistemlerinin Uygulama Alanları

Aktivite tanıma sistemleri son yıllarda akademik çalışma yapanların ve teknoloji şirketlerinin ilgi alanlarına girmiş olup birçok araştırmaya konu olmuştur. Bu sebeple birçok araştırmacı herhangi bir aktiviteyi türünü tanımlamak için farklı uygulama alanları önermiş ve bu alanlar da belirlenen hedeflere ulaşmaya çalışmışlardır. Bu şekilde aktivite tanıma sistemlerinin uygulama alanları belirlenmiştir. Bu uygulama alanları başlıca dört maddede ele alınır. Bunlar;

- Çevresel yardımcı yaşam uygulamaları
- Sağlık izleme uygulamaları
- Güvenlik ve gözetim uygulamaları
- Tele-immersion uygulamalarıdır.

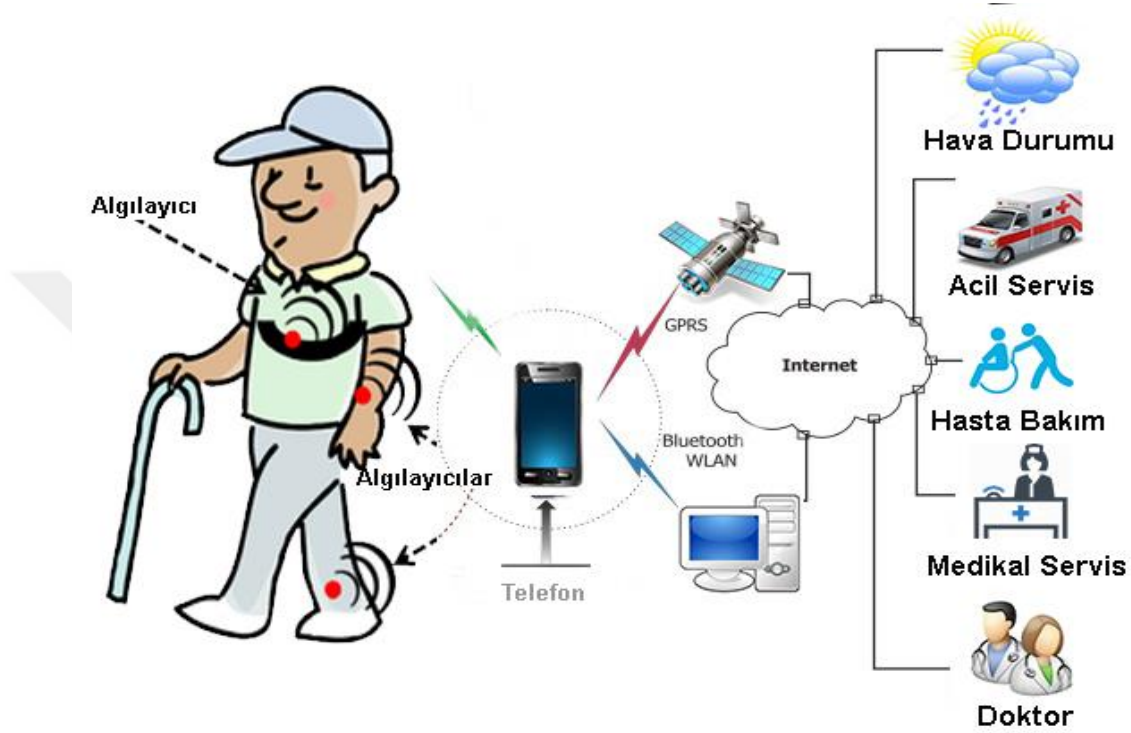
2.4.1. Çevresel yardımcı yaşam uygulamaları

Gün geçtikçe maliyetleri düşüp, yetenekleri artan kablolu ve kablosuz algılayıcılar yaygın olarak kullanılmaya başlanmıştır. Özellikle akıllı ev sistemlerinde (Şekil 2.11’de gösterildiği gibi) birçok amaçta kullanılmaya başlayan bu algılayıcılar başarılı sonuçlar elde etmektedir.

Genel olarak Kablosuz Algılayıcı Ağlar (KKA) WiFi, bluetooth vb. teknolojiler kullanarak bir cihazın başka cihazlarla kablosuz bir şekilde etkileşim kurması anlamına gelir. Çevresel yardımcı yaşam uygulamalarında KKA kullanılarak birçok işlem gerçekleştirilebilir. Bunlardan bazıları ışıkların kontrolü, uzaktan ev kontrolü, evde sağlık, evde bakım, kumanda sistemleridir (Gomez *et al.* 2010).

Engellilerin ve yaşlıların mümkün oldukça dışarıdan destek almadan, yalnız yaşamaya devam edebilmeleri için geliştirilen sistemler evde bakım ve sağlığa örnek gösterilebilir.

Bu nedenle, arařtırmacılar, tıbbi acil durumları ele alarak bir hastanın hastanede kalıřını ve kendisine yapılan ziyaretleri kısaltacak mevcut saęlık bakım izleme yaklařımlarını geliřtirmeye alıřmaktadırlar.



Őekil 2.12. Uzaktan kontrol ve saęlık izleme uygulamaları hasta takibi aısında verimli sonular elde etmektedir

Temel olarak saęlık bakım izleme sistemleri, dűřme algılaması, insan izleme, gűvenlik alarmı veya biliřsel yardım unsurları gibi bir veya daha fazla aktivite tanıma bileřeni kombinasyonuna dayanarak tasarlanmıřtır. Saęlık sistemlerinin oęu algılayıcıları, hasta vűcuduna ve evresine yerleřtirilir. Yardıma ihtiya duyulduęunda, sistem ilgili taraflara (dięer bir deyiřle tıbbi personele) durumu bildirir. Gűvenli dűřme algılama ve bildirim sistemleri daha ok giyilebilir algılayıcı sistemlerle otomatik olarak algılamak ve ilgili kiřileri bilgilendirerek kullanılmıřtır. İlk zamanlarda alarm vb. uyarı sistemi kullanılsa da geliřen teknolojiyle birlikte e-posta, SMS vb. iletiřim araları daha yaygın kullanılmaya bařlanmıřtır.

Akıllı yaşam destek sistemi (SAIL), bir yaşlı ya da engelli bireyin sağlık durumunu izlemek için geliştirilen robotun hastayla etkileşim kurması ve bilgilendirmeler yapmasını kapsar (Vacher *et al.* 2015). SAIL vücut algılayıcı sistemi, yardımcı robot, akıllı telefon ve uzak bir sağlık sağlayıcısından oluşur.

AB tarafından finanse edilen bir AB sağlık hizmetleri projesi olan CAALYX7 de yaşamsal aktiviteleri algılama ve acil bakıma ihtiyaç olan zamanları anladığında otomatik olarak bildirme yeteneğine sahip bir giyilebilir cihaz ile yaşlı insanlara yardım etmeyi amaçlamaktadır. En önemlisi, CAALYX acil ekibine hastanın mevcut konumu ve oraya gidilmesi gerektiği bilgisinin yanı sıra hastanın tıbbi durumu ve ihtiyaçlarını da bildirebilir. Bu yolla hastaya ulaşacak ekibin ihtiyacı olacak ekipmanı yanında bulundurması acil müdahalelerde büyük bir avantaj sağlar.

2.4.3. Güvenlik ve gözetim uygulamaları

Geleneksel izleme sistemleri, Şekil 2.13'de gösterildiği gibi insan operatörleri tarafından gerçekleştirilir. Kamera görüntüleri aracılığıyla anlık gözlem yapılabilse de insan faaliyetlerinin operatörler tarafından sürekli izlenmesi oldukça zor bir durumdur. Gün geçtikçe sayıca artan kamera ve bu kameraların görüş açılarının genişlemesi operatörlerin çalışmalarını daha stresli ve zor hale getirmektedir. Tüm bu zorluklar verimlilik düzeyini de oldukça düşürmektedir. Sonuç olarak güvenlik firmaları insan operatörü süreçlerini otomatikleştirmek ve kamera görüntülerinde anormallikleri tespit etmek için geliştirilen teknolojilerden yararlanmayı istemektedirler. Bu anlamda birçok çalışma gerçekleştirilmiştir.



Şekil 2.13. İnsan faaliyetlerinin operatörler tarafından sürekli izlenmesi oldukça zor ve maliyetlidir (Anonymous 2015)

Geleneksel nesne tanıma yöntemlerinin çoğu nesnenin şekline bağlı olmakla birlikte, bu yaklaşımları dağınık, geniş açılı ve düşük detaylı görüntülerden oluşan bir gözetim sistemine uygulamak oldukça zordur (Brémond *et al.* 2006). Dolayısıyla, önerilen uygulamalar, gürültü, tıkanıklıklar, gölgeler vb. çevresel ve bağlamsal konuları ele almaya muktedir olmalıdır.

Kapalı bir ortamda insan aktivite tanıma (HAR) sistemini etkileyen sebepler dış ortam nedenlerinden farklıdır. Örnek olarak, bir bankanın içinde kullanılan bir yaklaşım, metroya veya hava limanına yakın olan kalabalık bir yere uygulanamayabilir. Bu yaklaşımlar genel anlamda sağlam ve gerçek dünya uygulama koşullarında çalışabilir olmalıdır.

F. Brémond ve arkadaşlarının sunmuş oldukları gözetim sistemi, VSIP (Video Gözetim Yorumlama Platformu) üzerine kuruludur. Burada bir veya birkaç kamera görüntüsünü kullanarak bir metro sisteminde meydana gelen kavga veya hırsızlık olayları gibi insan davranışlarını tanıyabilmektedir (Brémond *et al.* 2006). Buna ek olarak C. Chang ve arkadaşlarının yapmış olduğu çalışmada, bir hapisanedeki bir grup kişinin şüpheli ve agresif davranışını başarılı bir şekilde tahmin edildiği gösterilmiştir (Chang *et al.* 2010).

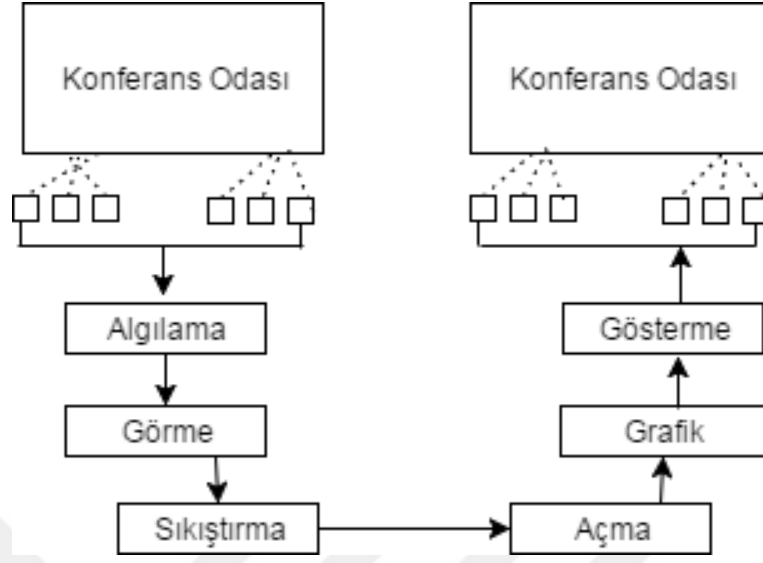
Bu arařtırmada arařtırmacılar, yürüme, farklı gruplar ve saldırganlık senaryolarını gerçek zamanlı ve kalabalık bir ortamda tespit etmek için birden fazla kamera görüntüsü kullanmışlardır. Aynı proje kapsamında bagaj boşaltma, uçak varış hazırlığı, yakıt ikmali gibi karmaşık faaliyetleri de içeren elli çeşit aktivite tanıma işlemi gerçekleştirilmiştir.

Bunun gibi çalışmalarda görüldüğü üzere hayatımızın her alanına giren izleme sistemlerinin aktivite tanıma işlemi de kullanarak birçok güvenlik problemini çözdüğü görülmektedir.

2.4.4. Tele-immersion uygulamaları

Tele-immersion sistemi çeşitli yerlerdeki bireylerin tek bir sanal ortamı paylaşmasını sağlamaktadır. Çok modlu ve sanal gerçekliğin, eğitim, bilim, üretim ve ortak bir karar vermede önemli uygulamaları bulunmaktadır. Bu teknoloji ayrıca bu şekilde büyüyen uygulamaların kalitesini ve miktarını artırmaktadır. Bu uygulamalar daha yüksek bir bilgisayar işleme gücü gerektirir ve gerçek zamanlı olarak bir ağ üzerinden aktarılması gereken büyük miktarda veri üretir. Genellikle, sıkıştırma yöntemleri, aktarılacak veri miktarını azaltmak için kullanılır.

Çok kameralı tele-immersion sistemi, hareket kestirimini kullanarak bulut verilerinden bir insan vücudunun her karedeki kinematik parametrelerini ayıklayabilir ve böylece uzaktaki siteler arasındaki ağ aktarımını büyük ölçüde en aza indirebilir (Lien *et al.* 2010). Şekil 2.14'te Tele-immersion mimarisi gösterilmektedir. Bu mimari konferans odasından uzak odaya sırasıyla algılama, görme, sıkıştırma, açma, grafik ve gösterme aşamalarının gerçekleştiğini göstermektedir.



Şekil 2.14. Konferans odasından uzak bir odaya doğru gerçekleşen tele-immersion mimarisinin aşamaları gösterilmektedir

2.5. Aktivite Tanıma Sistemleri ve Yaklaşımları

Görsel ve algılayıcı teknolojideki gelişmeler, aktivite tanıma sistemlerinin günlük yaşamda yaygın olarak kullanılmasına olanak sağlamaktadır. Son on yılda bilim adamları birçok uygulama alanındaki insan davranışını tanımaya yönelik çeşitli yaklaşımlar benimsemişlerdir. Aktivite tanıma sistemleri ve yaklaşımları bölümünü üç ana başlıkta inceleyebiliriz. Bunlar aktivite tanıma sistemleri için görsel sistemler, aktivite tanıma sistemleri için görsel olmayan sistemler ve çok modlu sistemlerdir.

2.5.1. Aktivite tanıma için görsel sistemler

Görsel algılayıcı ağları kullanarak insan faaliyetlerinin tanımlanması bilgisayar araştırma topluluğunda en popüler yaklaşımlarından biridir. Görsel tanımanın ilk günlerindeki sistemler el ve yüz hareketlerini tanıma ve video gözetim gibi kategorilerde incelemeler yapmıştır (Weinland *et al.* 2011).

Birçok algılayıcı veriyi tek boyutlu bir veri sinyali olarak sunarken görsel algılayıcılar veriyi görüntü olarak görülen iki boyutlu bir veri kümesi halinde sunar. Çeşitli görsel

tabanlı aktivite tanıma yaklaşımları vardır. Bu yaklaşımlar başlıca ortam destekli yaşam ve akıllı ev sistemleri için görsel aktivite tanıma sistemleri, sağlık izleme sistemleri için görsel aktivite tanıma sistemleri, güvenlik ve gözetim için görsel aktivite tanıma sistemleri ve spor ve açık havada görsel aktivite tanıma sistemlerinin alt başlıklarında inceleyebiliriz.

Çevresel yardımcı yaşam sistemlerinde görsel sistemler

Çevresel yardımcı yaşam ve akıllı ev sistemleri, iç mekân ortamlarında görsel algılayıcı kullanımını göz önüne alırsak çevresel yardımcı yaşamdan destek alan sakinlerin rahatlığını sağlayabilmek için gözetim ve yardım sağlar. Çevresel yardımcı yaşam kolaylıkla sonuçlandırılabilir olmalı ve aynı zamanda gerektiğinde kullanıcılara yardımcı olabilecek sağlam sistemler olmalıdır.

Aktivite tanıma için bir izleme sistemi üzerine B. Fosty ve arkadaşları hiyerarşik model tabanlı bir yaklaşım kullanan aktivite tanıma için bir RGB_D kamera izleme sistemi sunmuşlardır. Bu yaklaşımın amacı demanslı hastalara bağlı olarak değerlendirilen fiziksel görevleri tanımdır. Kompleks olayları video dizilerinden çıkarılarak veri akışıyla deney yapılmıştır. Bu deneylerde denge testi, yürüme testi, tekrarlanan gönderim testi ve hareketli testler gibi aktivite testleri yapılmış olup %95,4 doğruluk oranlarını tespit edilmiştir (Fosty *et al.* 2013).

Bir başka araştırmada araştırmacılar; Shotton ve arkadaşları tarafından 3B iskelet eklem yerlerini Kinect derinlik haritalarından çıkardılar. Ardından hesaplanan 3D eklem yerlerinin histogramlarını (HOJ3D), doğrusal diskriminant analizi (Linear Discriminant Analysis) kullanarak eylem derinlik dizilerinden yeniden projelendirdiler ve eylemlerin prototip pozlarını temsil eden k duruş görsel sözcüklere kümelmişlerdir. Bu görsel kelimelerin zamansal evrimleri ayrık gizli Markov modelleri (HMM) ile modellenmiştir. Kapalı bir ortamda on çeşit insan eylemi (yani yürümek, oturmak, ayağa kalkmak vb.) içeren özel veri kümesi toplanmıştır. Deneysel sonuçlar, yürümek, oturmak, ayağa kalkıp almak, taşımak, atmak, itmek, çekmek, sallamak ve alkışlamak

gibi eylem türleri için toplam doğruluk oranının %90.9 olduğunu göstermektedir (Shotton *et al.* 2014).

Yine benzer bir başka araştırmada belirsizliği giderme amacıyla Romdhane ve arkadaşları olasılık sal mantıkla karmaşık bir olay tanıma yaklaşımını tanımlamışlardır. Önerilen olay tanıma algoritması, izlenen hareketli nesnelere girdi olarak (görüntü algoritmaları, bölütleme, algılama ve izleme ile çıkarılır), sahnenin öncül bir bilgisini ve önceden tanımlanmış modellerini kullanmaktadır.

Bir olayın olasılığını hesapladıktan sonra sistem, olasılıkları bir eşğin üstünde kabul ederek veya reddederek bir tanıma kararı verebilmektedir. Yürüyen etkinlik için %92.5, rehberli testi başlatmak için %100, bir sandalyeyle etkileşimde %100, mutfakta kalma konusunda %93.3 ve yemek hazırlamak için %87.5 doğrulukları tespit edilen deneysel sonuçlar kapalı olayların tanınması için daha yüksek bir doğruluk sunmuştur (Romdhane *et al.* 2011).

Sağlık izleme uygulamalarında görsel sistemler

Sağlık izleme uygulamalarında aktivite tanıma çok önemli yer tutmaktadır. Aktivite tanımayla birbirinden bağımsız birçok hastalığın takibi mümkündür. Demans, Alzheimer gibi hastalıklarla boğuşan hastaların unuttukları şeyleri çeşitli hatırlatıcılarla hastaya sürekli anımsatması bu konuya örnek gösterilebilir.

Entegre zaman hareketi görüntüleri (ITMI) ve Uzay Teknikleri ile kombine bir aktivite tanıma sistemi çalışmasını incelediğimizde yapılan çalışmalarda önerilen sistem, anormal ve olağandışı davranışlar da dahil olmak üzere çok çeşitli günlük yaşam aktivitelerini tespit edebilmektedir (Foroughi *et al.* 2008). Bu çalışmada araştırmacılar, herhangi bir hareket alanını çıkarmış ve bir değişiklik olayı üzerinde karar vermek için çok katmanlı algılayıcı (Multilayer Perceptron-MLP) nöral ağını kullanarak hareketi sınıflandırmışlar. Yapılan bu çalışma, nihai sonuç olarak %89.9'luk güvenilir bir tanıma oranını yakalamıştır. Bununla ilgili yapılan çalışmalar son zamanlarda tanımlama

oranını artırarak devam etmektedir. Hareketleri tanımlanmış ve belirlenmiş bir hastanın olağan üstü bir hareketinde hasta bakıcısına ilgili bir uyarı verilebilir.

Bir başka akıllı sağlık izleme sistemi çalışmasında, yaşlı bir hastanın bunama sebebiyle belirlenmiş bir alandan dışarıya kaçması olayını yapmış olduğu aktivitelerinden belirlenerek otomatik olarak hasta bakıcıya iletimi incelenmiştir. Bu izleme çalışmasında günlük faaliyetlerin görsel ve işitsel kayıtlarını toplamak için kameralar kullanılmıştır. HMM algoritması kullanarak toplanmış olan verilerin kullanılmasında kaçma olayını %100 oranında tahmin etmiştir (Chen *et al.* 2008). Deneysel sonuçların bu derece yüksek oranları bizlere gelecekte farklı cihazlar kullanarak birçok hastalığın izleme ve takip olaylarında ciddi gelişmeler sağlayacağını göstermektedir.

Açık alanda güvenlik ve gözetim uygulamalarında görsel sistemler

Son zamanlarda güvenlik ve gözetim sistemleri kamuya açık alanlarda yoğun bir şekilde kullanılmaktadır. Görsel algılayıcı tabanlı teknikler, video ve görüntülerin niteliklerinden dolayı sağlanabilecek geçerli deliller oluşturmak adına bu yaklaşım uygulanabilir. Bu konuda Nievas ve arkadaşlarının yapmış olduğu çalışmada, video içerisinde bulunan insanların aktivitelerinin tanımlanması ve kategorize edilmesi sağlanmıştır.

Bu çalışmada birçok yöntem kullanarak sahtekârlık, vandalizm, dövüş, engelleme, aşırı kalabalık şeklinde kategoriler hazırlanmıştır. Bu kategorilerde tahminleme oranı sahtekârlık %100 (6/6), vandalizm %100 (4/4), dövüş %83,3 (24/20), engelleme %100 (13/13) ve aşırı kalabalık senaryolarını başarıyla tamamlamıştır (Nievas *et al.* 2012).

Adli bir olayda olayın sicağı sicağına fark edilememesi büyük dezavantaj olmaktadır. Özellikle uzun kamera kayıtlarının takibi izlenerek yapıldığında yorucu, zaman alıcı ve gözden kaçırıcı ihtimali de yine dezavantajlara sebep olmaktadır. Tüm bu ve buna benzer dezavantajlara baktığımızda günümüzde popüler olan güvenlik ve gözetim

uygulamalarında aktivite tanıma çalışmalarının gelecekte de artarak devam edeceğini görmekteyiz.

Spor ve kapalı ortamlar da görsel sistemler

Bilgisayar görme teknikleri oyuncuların performansını artırmak, oyun planını analiz etmek ve spor faaliyetlerini tanımak için de kullanılabilir.

Direkolu ve arkadaşları bir hentbol oyununda ekip faaliyetlerinin bütün bir oyun alanını analiz etme yöntemi geliştirmişlerdir. Bu projede hareket özniteliklerini çıkarmak ve ekip oyuncularının konum dağılımını tanımak için çerçeve farklılaştırması ve optik akış metotları kullanılmıştır. Önerilen bu yaklaşım, Avrupa hentbol veri seti kullanılarak değerlendirilmiş ve bir hentbol oyununda altı farklı takım etkinliğini başarıyla tespit edebilmiştir (Direkolu *et al.* 2012). Bu etkinlikler yavaş yavaş atak yapma, savunma yaparken faul yapma, hızlı atak, hızlı müdahaleyi önlemek, hızlı dönüş ve temel savunma işlemleri şeklindedir.

Brendel ve arkadaşları olasılıksal olay mantığını kullanarak verilere dayanan bir basketbol videosunun olaylarını ve zaman aralıklarını tespit etmişlerdir. Basketbol olaylarını, yani top sürme, atlama, atış, yakalama, zıplatma vb. gibi olayları başarıyla tespit ettiler (Brendel *et al.* 2011).

Tang ve arkadaşları koşullu bir model kullanarak video akışlarındaki karmaşık olayları saptamak için bir yöntem geliştirmişlerdir. Bu yöntem, videolardaki ayırt edici ve ilgi çekici bölümleri otomatik olarak algılar. Zor görevleri saptamak ve tanımak için rekabet açısından daha yüksek bir doğruluk elde eder (Tang *et al.* 2012). Video çerçevelerindeki değişkenler olay için en ayırt edici durum dizisini keşfetmek ve atamak suretiyle kullanmıştır.

Touati ve Mignotte insan eylemlerini tanımak için video dizisi veri küpünün farklı bakış açılarından üretilen bir prototip seti oluşturmuşlardır. Bu prototipler, doğrusal olmayan

bir boyut azaltma tekniğine dayanan çok boyutlu bir ölçeklendirme kullanılarak üretilir. Bu strateji, insan vücudundaki her eylemi düşük boyutlu bir alanda, video küpünün her bir bakış açısı için noktaların yörüngesini veya belirli bir eğri olarak modelleme yöntemini amaçlamaktadır. Daha sonra, bir KNN sınıflandırıcısı, tanımlanacak her bir eylemle ilişkili prototipi sınıflandırmak için kullanılmaktadır. Her bir görüş açısının sınıflandırma sonuçlarının birleştirilmesi, tanıma oranı performansını arttırmak için kullanılmış olup genel performans, yürüme, koşu, atlama, kriket, atlama, bükme gibi etkinlikleri tanımak için %92,3'lük bir doğruluk yüzdesine ulaşmışlardır (Touati *et al.* 2014).

2.5.2. Aktivite tanıma için görsel olmayan sistemler

Görsel tabanlı analizin yanı sıra, araştırmacılar insan davranışını otomatik olarak algılamak için insan seslerini analiz etme, algılayıcı tabanlı algılama vb. birçok girişimde bulunmuşlardır. Bu girişimlerde kullanılan araçlar hareket algılayıcılar, RFID etiket okuyucuları vb. basit algılayıcılar olduğu gibi karmaşık ses işleme ve aktivite tanıma için ivmeölçer vb. gelişmiş algılayıcılar da olabilmektedir. Ayrıca duruş ölçümü için fiber optik algılayıcılar, solunum hızı ölçümü için basınç algılayıcıları ve oksimetre algılayıcıları, deri iletkenlik algılayıcıları, elektrokardiyograflar, vücut sıcaklığı algılayıcıları vb. algılayıcılarda bu araçlara dahil edilebilir.

Küresel anahtarlar ve RFID etiket okuyucuları gibi basit algılayıcılardan, karmaşık ses işleme ve bilgisayar görme algılama için kullanılan ivmeölçere kadar, etkinlik tanıma için kullanılacak çeşitli algılayıcı türleri vardır. Ayrıca, duruş ölçümü için de fiber optik algılayıcılar, solunum hızı ölçümü için köpük basınç algılayıcıları ve oksimetre algılayıcıları, cilt iletkenliği algılayıcıları, elektrokardiyograflar ve vücut sıcaklığı algılayıcıları gibi fizyolojik algılayıcılarda diğer algılayıcılara dahil edilebilir (Huynh *et al.* 2008).

Ortam destekli yaşam sistemlerinde görsel olmayan aktivite tanıma sistemleri

Akıllı ev teknolojileri, ev sakinlerinin davranışlarını belirlemek için ışık, ses, temas, hareket ve durum değişiklikleri sağlayan çeşitli algılayıcılar kullanmaktadır. Fleury ve arkadaşları destek vektör makinelerini kullanarak bir akıllı evdeki günlük yaşam aktivitelerinin sınıflandırılmasına ilişkin çalışmalar yapmışlardır (AFleury *et al.* 2010). Önerilen yöntem konum algılayıcıları, mikrofonlar, giyilebilir algılayıcılar, sıcaklık ve hidrometre algılayıcıları kullanarak yedi aktiviteyi (hijyen, tuvalet kullanımı, yemek yeme, dinlenme, uyku, iletişim ve giyinme / soyunma) tespit edebilmiştir.

Avantajları tartışılmaz olan bazı algılayıcılar bazen güncel bilgileri yanlış okuyarak, geliştirilen sistem tutarsız ve güvenilmez hale getirebilmektedir. Bu anlamda birçok araştırmacı güvenilirlik düzeyini karar verme süreciyle birleştirerek belirsizliğin giderilmesi için farklı çalışmalar yapmışlardır. Bu şekilde elde edilen verilerin güvenilirliğini artırarak ortam destekli yaşam sistemlerinde görsel olmayan aktivite tanıma sistemlerinin yaygın olarak kullanılması sağlanmıştır.

Diğer kapalı ortamlarda görsel olmayan aktivite tanıma sistemleri

Literatürler incelendiğinde akıllı ev sistemlerinin yanı sıra, diğer algılayıcı tabanlı kapalı sistemlerin de çokça incelendiği görülmüştür. Bir örnek olarak Viani ve arkadaşları kapalı bir altyapı olmayan ortamın pasif hedeflerini izleyebilen ve yerinde belirleyebilen örnek bir öğrenme yaklaşımı geliştirmişlerdir. Bu yaklaşım, hedefler ile kablosuz bağlantılar arasındaki etkileşimi kullanmıştır. Böylece önerilen strateji, nesnelere izlemek için belirli herhangi bir cihaz veya belirli bir algılayıcı kullanımına ihtiyaç duyulmamıştır (Viani *et al.* 2009).

Bu anlamda kapalı bir müzede hırsızlık girişimlerini engellemek için geliştirilen sistemler bulunmaktadır. Bu sistemler müzenin içindeki sanat eserlerini izleyebildiği gibi ziyaretçilerin davranışlarını kablosuz algılayıcı ağı (WSN) kullanarak tahmin edebilmektedir. SN'de bulunan çoklu algılayıcılar tüm bilgileri bir merkezi kontrol

ünitesinde toplamakta ve verileri eş zamanlı olarak işlemektedir. Bu şekilde işlenmiş olan verilerin değişim durumunda bilgileri anlık olarak müze görevlilerine bildirmektedir.

Wang ve arkadaşlarının yapmış olduğu bir çalışmada kamera seri arabirimi (CSI) hız modelinden-hız ve CSI-aktivite modelinden oluşan bir CSI tabanlı insan aktivitesi tanıma ve izleme (CARM) sistemi geliştirilmiştir (Wang *et al.* 2015). CARM koşu, yürüme, oturma, buzdolabını açma, düşme, boks yapma, itme, dişleri fırçalama aktivitelerini ortalama %96 doğrulukla tespit etmiştir. Ayrıca yapılan bu çalışma laboratuvarında %90, lobide %93 ofiste %83 ve dairede %80 oranında doğru bir şekilde aktiviteyi tahmin etmiştir.

2.5.3. Aktivite tanıma yaklaşımları için çok modlu sistemler

Son zamanlarda çok modlu aktivite tanıma yaklaşımları popüler hale gelmiştir. İnsan faaliyetlerini tanımak için görsel ve görsel olmayan algılayıcılar aynı anda kullanılabilir. Kullanıcı gereksinimlerine bağlı olarak, algılayıcıların kullanımı farklı olabilir. Örneğin, bir kamera belirli bir alanı görüntüleyebilir. Fakat çevre sıcaklığı, nem ve kalp atış hızı gibi kullanıcı bilgilerinin hassas verilerini analiz için yeterli değildir. Tek bir algılayıcı yaklaşımını kullanan sistemler, bu tür farklı girdi verisine ihtiyaç duyulan durumlarda iyi performans göstermezler. Bu sınırlamaların üstesinden gelmek için aynı algılama sisteminde çeşitli algılayıcılar kullanılabilir. Örnek olarak çoklu algılayıcı, kamera ağları, vücuda takılan algılayıcılar ve mobil cihazlar verilebilir.

AAL ve Akıllı Ev Alanında Çok Modlu Sistemler

Video tabanlı yaklaşımlarla karşılaştırıldığında, ilgili alanlardaki insanların gizlilik kaygısı göz önüne alındığında algılayıcı tabanlı teknolojiler AAL alanlarında daha yaygın olarak kullanılmaktadır. Bu anlamda çalışma yapan Vacher ve arkadaşları yarı-markov modellerini kullanarak akıllı evlerde ADL'leri öğrenme ve tanımlama sorununu ele almıştır ve gündelik hayatta sıradan yaşam sürdüren birinin davranışlarını

öğrenebileceği hiyerarşik yapılar kullanmışlardır (Vacher *et al.* 2016). Bu çalışmada kişinin anormal davranışları saptanmıştır.

Bir başka araştırmayı incelediğimizde Chen ve arkadaşları çok algılayıcı veri akışlarını kullanarak bilgi odaklı bir yaklaşım başlatmışlardır. Bu yaklaşım çeşitli ADL'ler ve kullanıcı senaryoları kullanılarak değerlendirilmiştir. Diş fırçalamak, kahve yapmak, banyo yapmak, TV izlemek, çikolata yapmak, makarna yapmak ve el yıkamak gibi aktivitelerde %94.44'lük tanıma oranı elde edilmiştir (Chen *et al.* 2012).

Çok modlu gözlem verilerinden insan davranışlarını öğrenen ve tanıyan akıllı bir ev ortamı yaklaşımıyla ilgili de birçok çalışma bulunmaktadır. Bir alanda kişileri izlemek için 3D video izleme sistemi ve herkesin ses akışını analiz etmek için bir konuşma aktivitesi algılayıcısının kullanılması Brdiczka ve arkadaşlarını çalışmalardan birisidir. Sistem "yürümek" veya "masa ile etkileşim kurma" gibi temel bireysel etkinlikleri belirleyebilmiştir (Brdiczka *et al.* 2009).

Sağlık Hizmetlerinde Çok Modlu Sistemler

Çok modlu algılayıcılar, hastaların sağlık durumunu izlemek için gözlem araçları olarak kullanılır. Maurer ve arkadaşları eWatch adlı platformu kullanarak vücudun farklı noktalarına yerleştirilen algılayıcılar sayesinde bir kişinin faaliyetlerini izleyen çok algılayıcı bir platform oluşturdu (Maurer *et al.* 2006).

Kullanıcı faaliyetlerini gerçek zamanlı olarak tanımlarken gün içindeki sınıflandırma sonuçlarını kayıt edilebiliyordu. Ardından, tanıma doğruluğu ile hesaplama karmaşıklığı arasındaki dengeyi analiz etmek için çok zamanlı alan özelliği kümeleri ve örnekleme oranları karıştırılmaktadır. Sınıflandırma doğruluğu, altı farklı vücut noktasından (bilek, cep, çanta, kolye, gömlek ve kemer) toplanan her aktivite için hesaplanır. Nihayet genel sınıflandırıcıyı eğitmek için tüm konulardaki veriler bir araya getirilir. Yapılan değerlendirme sonucunda, elde edilen veriler, 6 farklı noktada da yürüyüş, ayakta durma, oturma ve koşu aktivitelerini tespit etmek için iyi olduğunu gösterdi. Bu

sonuçlara dayanarak, arařtırmacılar eWatch içinde çalıřan bir karar aęacı sınıflandırıcısı geliřtirmişlerdir.

Dıř Ortamda Çok Modlu Sistemler

Çok modlu algılayıcılar, arařtırmacılar tarafından dıř ortamdaki insan faaliyetlerini tespit etmek içinde kullanılır. Al Machot ve arkadaşları Answer Set Programming kullanarak karmařık olayları otomatik olarak saptamak için Çoklu Algılayıcı Aęını (SRSnet) sundu (Al Machot *et al.* 2011).

SRSnet sistemi, ses ve video iřleme bileřenlerini temel alır. Sistem, ses ve video veri iřlemelerindeki basit olayları bir araya getirerek karmařık olayları tespit eder. Tespit edilen olaylar ve PTZ yapılandırması hakkında bilgi, aę alt sistemi için giriři oluřturur. Tespit edilen karmařık ve basit olaylar bir multimedya veri ambarında saklanır. SRSnet'in deneysel sonuçları, grup çalıřması ve farklı yönde ilerleyen insanlar için tespit oranının %94'ün üzerinde olduęunu gösterdi.

Bir bařka arařtırmada Theekakul ve arkadaşları insan faaliyet sınıflandırması için kural tabanlı bir sistem oluřturdular (Theekakul *et al.* 2011). Bu sistem kural öğrenmesi ve kural tabanlı çıkarım olmak üzere iki temel bileřenden oluřur. Sınıflandırma kurallarını oluřturmak için algılayıcı verileri alana özgü bilgilerle birlikte kullanılır.

Eęitim ve test iřlemleri için bir oryantasyon programı ve temel kurallar dizini uygulanmıştır. Test veri setleri yalan söyleme, oturma ve ayakta durma, yürüme, kořu ve atlama faaliyetlerini başarıyla algılamıştır. Algılama, sırasıyla eęitim ve test veri setleri için %76.43 ve %74.46'lık bir doęruluk ile gerçekteřirilmiştiir.

Mobil Tabanlı Çok Modlu Sistemler

Günümüzdeki mobil cihazların çoğunda GPS, ses (yani mikrofonlar), görüntü (kamera), sıcaklık, yön (pusulalar) vb. algılayıcılar bulunur. Sonuç olarak, mobil cihazlar araştırmacıların yararlanması ve insan faaliyetlerinin tanınması için yenilikçi çözümler bulmak adına geniş bir bakış açısı sağlamaktadır.


Lara ve arkadaşları ivme algılayıcı verilerini hayati işaretlerle (örn. kalp hızı, solunum hızı vb.) birleştiren bir mobil platform olan Centinela'yı oluşturmuşlardır (Lara *et al.* 2012). Bu platform, taşınabilen ve göze batmayan gerçek zamanlı bir sistemden oluşmaktadır. Centinela, yürüyüş, koşu, oturma, yükselen ve inen aktiviteler olmak üzere beş farklı etkinliği tanımlamaya çalışmaktadır. Değerlendirmede uygulamanın yürüme, koşma ve oturma faaliyetlerini tanımlamada %92.6 civarında bir doğruluk oranına ulaştığı gözlemlenmektedir.

Kwapisz ve arkadaşları insan aktivitelerini tanımak için telefonla çalışan ivmeölçer kullanan bir sistem geliştirmişlerdir (Kwapisz *et al.* 2011). Bu sistemde yürüme, koşma, merdiven çıkma, merdiven inme, oturma ve ayakta durma aktivitelerinin verileri toplanarak analiz edilmiştir. Deney sonuçları %90'ın üzerinde bir aktivite tanıma oranını göstermiştir.

2.6. Algılayıcılar

Algılayıcı, otomatik kontrol sistemlerinin kullanmış olduğu algılamayı temel alan cihazlara verilen addır. İnsanların çevrelerinde olup bitenleri duyu organlarıyla algılamasına benzer biçimde, makineler de sıcaklık, basınç, hız ve benzeri değerleri algılayıcıları vasıtasıyla algırlar.

Teknolojideki hızlı gelişme ile elektronik parçalar ve algılayıcıların boyutları küçülmüş olup mikro boyutlarla ifade edilebilir hale gelmiştir. Küçülen bu algılayıcılar birçok cihazın içerisine girmiş ve kullanışlı bir duruma gelmiştir. Cep telefonu bu cihazlara




Şekil 2.16. Bir cep telefonunda bulunan ivmeölçerin eksenleri x, y ve z'den oluşmaktadır

İvmeölçer verileriyle hızlanma hesaplanabildiğinden GPS ile konum hesaplama daha doğru konum tespiti için kullanılmaktadır. Bu anlamda navigasyon için kullanımı çok elverişlidir. Günümüz telefonlarında titreşim engelleyici göreviyle kameraların görüntüyü netleştirmesine yardımcı olur.

2.6.2. Jiroskop (Gyro/Gyroscope)

Türkçe adıyla düzdöner, dönüş ekseninin kendi kendine herhangi bir yönü kabul etmekte özgür olduğu, dönen bir çarktır. Açısal hızın korunmasına göre döndüğü için, döndüğü eksenin yönünün devrilmesinden veya dayanağın yönünün değişmesinden etkilenmez. Bundan dolayı jiroskoplar yön ölçümü veya ayarlamasında kullanılır.

Uçak ve gemilerin hareketlerini kontrol etmek için jiroskopik türleri geliştirilmiştir. Uçaklarda, otomatik uçuş ve rota bulmada önemli kullanım alanına sahipken gemilerde yalpa hareketlerini önlemektedirler. Petrol kuyularında faydalı olarak ekseninin şaşmaması için kullanılır. Gündelik hayatta kullanmış olduğumuz telefondaki 'Ekran döndürme' özelliği jiroskopun kullanılmasıyla gerçekleştirilmiştir.



Şekil 2.17. Jiroskoplar yön ölçümü veya ayarlanmasında kullanılırlar

2.6.3. Barometre (Barometer)

Atmosfer basıncını ölçmeye yarayan algılayıcıdır. Belirli seviyelerde basınç ölçümü gerçekleştirebilir. Genel olarak yüksek hassasiyetli, düşük güçlüdürler. Barometreler civalı ve havalı barometre olarak ikiye ayrılır. Bu iki barometre çalışma esasına göre ayrılmış olup günümüzde dijital barometreler bulunmaktadır. Bu dijital barometreler birçok akıllı telefonun içerisinde barometre algılayıcılarıyla yer almaktadır.




Şekil 2.18. Teknolojinin gelişmesiyle birlikte dijital barometreler sıklıkla kullanılmaya başlanmıştır

Günümüzde sağlıklı yaşam uygulamalarına katkıda bulunmaktadır. Ayrıca GPS navigasyon, bina içi açık havada navigasyon, hava durumu tahmin, dikey hız göstergesi vb. işlemlerde de kullanılmaktadır.

2.6.4. Pusula (Magnetic Sesor)

Dünya üzerinde yön tespit etmeye yarar. Yönler genel olarak bu araç ile bulunur. Yaygın olarak GPS ve navigasyon işlemlerinde kullanılmaktadır. Manyetik algılayıcı olarakta bilinir.




Şekil 2.19. Dünya manyetik alanına göre x,y,z değerleri gösterilmiştir

Pusulalar, mekanik bir düzenele serbest hale getirilmiş bir tekerin ortasından geçen bir eksen etrafında çok hızlı döndürüldüğünde uzayda sabit bir noktayı göstermesi prensibine dayanılarak geliştirilmiştir.

Pusula manyetik bir alettir. Bundan dolayı etrafındaki metal olan her şeyden etkilenir. Pusulanın etrafındaki metal anahtarların, demir içeren çantaların, araçların; cep telefonu, televizyon, tablet, PC gibi manyetik alan yayan aletler pusulamızın verimli çalışmasını engelleyebilir.

2.6.5. Işık algılayıcısı

Ortamdaki aydınlığı ölçer ve özellikle cep telefonlarda bulunan ışık algılayıcılar ortam ışığına göre aydınlatma işlemini otomatik olarak ayarlar. Bu algılayıcı sayesinde gözü yormayan ışık şiddeti ayarlanırken enerji tüketiminde de tasarruf sağlanabilmektedir.



Şekil 2.20. Işık algılayıcıları sayesinde gün ışığına göre aydınlatma işlemi gerçekleştiren sokak aydınlatma aletleri

Işık algılayıcıları günümüzde sokak, bina vb. aydınlatma araçlarında, araç içinde, hastahanelerde, havalimanlarında vb. birçok yerde yaygın olarak kullanılmaktadır.

3. MATERYAL ve YÖNTEM

Bu bölümde aktivite seçimi, aktivite tanıma için gerekli olan veri setinin elde edilme aşamaları ve aktivite tanımda kullanacağımız yöntemler açıklanmıştır. Sırasıyla yapılacak işlemler aşağıda gösterilmiştir.

- Aktivite seçimi
- Veri toplama
- Öznitelik çıkarma
- Sınıflandırma
- Performans ölçütleri

3.1. Aktivite Seçimi

Bu çalışmada, günlük hayatta yapılması muhtemel dokuz adet aktivite belirlenmiştir. Aktiviteler aşağıda belirtilmiştir.

- Merdiven Çıkma
- Merdiven İnme
- Yürüme
- Araç Kullanma
- Uzanma
- Yemek Yeme
- Oturma
- Ayakta Durmak
- Koşma

3.2. Veri Toplama

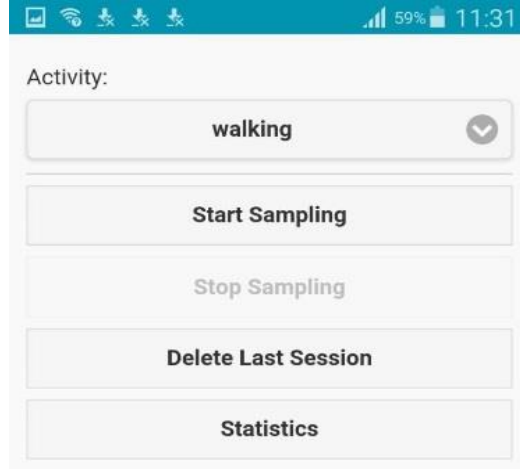
Üst bölümde belirtmiş olduğumuz aktiviteler kullanılarak veri toplama işlemi için akıllı telefon uygulaması geliştirilmiştir. Verilerin toplanması için algılayıcıdan veriyi alacak ve bu veriyi belirlenen frekans değeriyle, yine belirlenen bir alana yazacak uygulama ihtiyacı bulunmaktadır.

Yaygın olarak mobil uygulamaların çoğu Android, Iphone/Ipad ve Windows telefonları için geliştirilmektedir. Bu konuda her üç işletim sistemi için uygulama geliştirmek isteniyorsa üç konuda da ayrı ayrı uzmanlaşılması veyahut hibrit bir uygulama çıkarılması gerekmektedir.

Piyasadaki platformları incelediğimizde Apache Cordova geliştirilecek uygulama için ideal bir platform olduğuna karar verilmiştir.

Apache Cordova ile Web'ten nativeye uygulama geliştirilebilmektedir. Bu özeliğinden dolayı yapmış olduğumuz yazılımın Android, IOS, Windows Phone vb. birçok işletim sistemine çalışacak şekilde çıktısını alınabilmektedir. Apache Cordova, mobil uygulamalar içerisinde web siteleri görüntülemek amacıyla kullanılan Web View yapısını kullanarak mobil uygulama geliştirmemize olanak tanımaktadır.

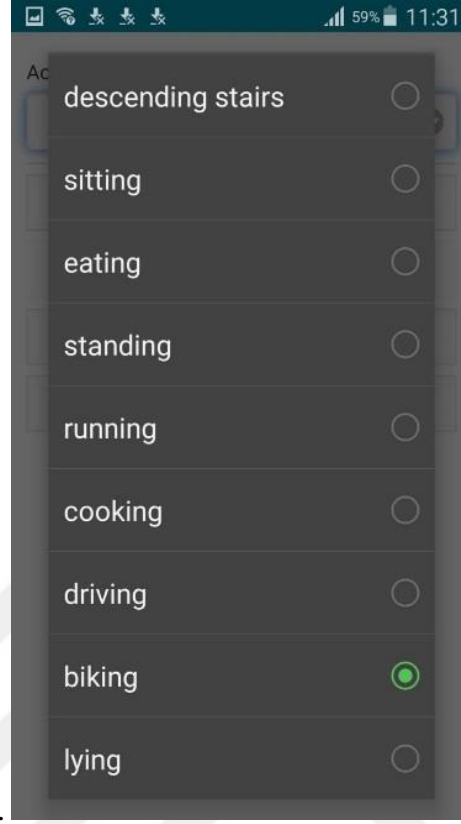
Bu teknoloji HTML5, CSS3 ve JavaScript web teknolojileri dışında ekstra bir teknoloji öğrenmeksizin kolayca mobil uygulama geliştirmemizi sağlamaktadır.



Şekil 3.1. Geliştirmiş olduğumuz uygulamanın ana ekran görüntüsü

Geliştirilen uygulama ana ekranı Şekil 3.1’de gösterildiği gibidir. Ana ekran aktivite türünü seçilebileceği bir alan, veri toplamaya başlama butonu, durdurma butonu, son sesyonu silme butonu ve istatistik butonundan oluşmaktadır.

Aktivitenin altında bulunan açılır menüyü tıkladığında Şekil 3.2’de gösterildiği gibi bütün aktiviteler listelenmektedir. Aktiviteye başlarken elde edilecek veri aktiviteye göre buradan seçim yapılarak bir sonraki başlat tuşuna basılması gerekmektedir. Örnek olarak koşma aktivitesini yapmak isteyen biri ana menüden aktivite seç tıkladığında açılan menüden koşma butonuna seçer ve başla ile yapmış olduğu koşma aktivitesinin ivmeölçer değerlerini kayıt etmeye başlar.



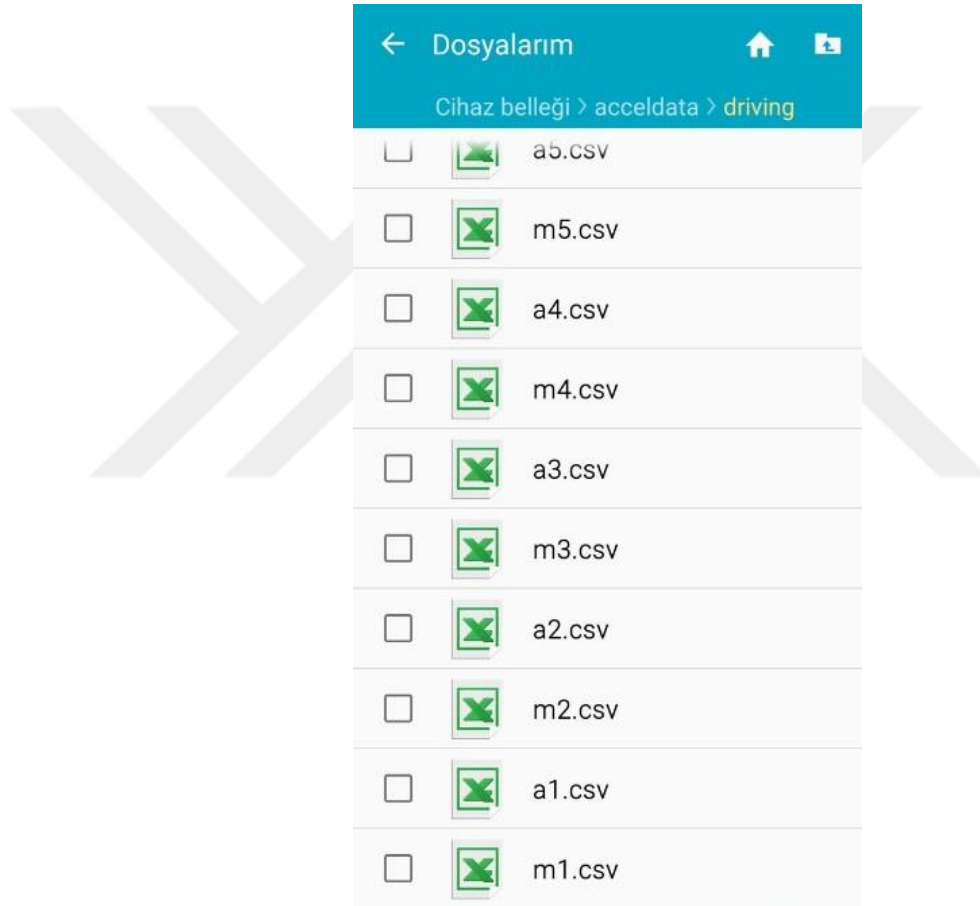
Şekil 3.2. Ana ekranda bulunan açılır menünün içerisinde kullanacağımız bütün aktiviteler bulunmaktadır

Aktivite seçimini gerçekleştirdikten ve başlat tuşuna bastıktan sonra telefonda belirlediğimiz bir dosya içine seçmiş olduğumuz aktivite isminde bir klasör oluşturulmaktadır. Örneğin yürüme aktivitesini seçtikten sonra başlat düğmesine basarsak belirlediğimiz konumda yürüme klasörünü oluşturulmaktadır. Eğer önceden aynı klasör var ise tekrar klasör açmaz ve veri var olan klasör içine yazılır.

Klasör oluşturduktan sonra klasör içine ivmeölçer ve pusula verilerini yazmak amacıyla iki adet CSV dosyası oluşturulur. Bu CSV dosyaları Şekil 3.3'te gösterildiği gibi a1 ve m1 şeklindedir. Oluşan a1.csv dosyasına ivmeölçer verileri, m1.csv dosyasına ise pusula verileri yazılır.

Buradaki CSV dosyaları oluşturulurken isimlendirme işlemi 'a' ve 'm' harflerinin yanındaki rakamı ardışık olarak 1'er artırılarak yapılır. Örnek olarak koşma aktivitesi

seçiliyken başlat düğmesine basıldığı takdirde ilk olarak koşma klasörünün var olup olmadığına bakılır eğer var ise klasörün içindeki CSV dosyaları kontrol edilir. Duruma göre yeni veyahut numaralandırmayı bir artırarak iki CSV dosyası oluşturulur ve içine verileri yazmaya başlanır. Eğer klasör yok ise üst bölümde anlatıldığı gibi koşma klasörünü oluşturulur ve içerisinde a1 ve m1 isiminde yeni CSV dosyaları oluşturularak veri yazılmaya başlanır.



Şekil 3.3. Veriler varsayılan klasör içerisinde a ve m şeklinde dosyalar oluşturmakta

Oluşturulan CSV dosyalarının içine ivmeölçerden gelen X,Y,Z verilerini programda belirlemiş olduğumuz frekans değerine göre satır satır yazmaktadır. Çizelge 3.1’de görüldüğü üzere sırasıyla tarih, saat, dakika, saniye cinsinden zaman ve X,Y,Z değerleri sütunları oluşturmaktadır.

Çizelge 3.1. Geliştirmiş olduğumuz uygulama aracılığıyla kaydedilen ham verilerden örnekler

Milisaniye	X	Y	Z	Aktivite
88403198	6,56	-1,61	-7,42	Uzanma
88403213	6,54	-1,59	-7,41	Uzanma
88403227	6,56	-1,58	-7,39	Uzanma
88403261	6,56	-1,62	-7,41	Uzanma
34415472	4,36	6,74	-6,32	Yemek Yeme
34415507	4,47	6,71	-6,31	Yemek Yeme
34415522	4,42	6,68	-6,31	Yemek Yeme
34415537	4,45	6,66	-6,32	Yemek Yeme
36671545	0,38	9,88	-0,29	Merdiven Çıkma
36671561	0,43	9,91	-0,25	Merdiven Çıkma
36671577	0,41	9,87	-0,23	Merdiven Çıkma
36671609	0,42	9,85	-0,21	Merdiven Çıkma
28663507	2,04	9,15	1,16	Merdiven İnme
28663524	2,03	9,13	1,15	Merdiven İnme
28663556	2,06	9,15	1,12	Merdiven İnme
28663604	2,05	9,15	1,09	Merdiven İnme
84097575	2,44	9,72	-0,11	Ayakta Durma
84097587	2,43	9,71	-0,09	Ayakta Durma
84097604	2,42	9,73	-0,07	Ayakta Durma
84097660	2,41	9,72	-0,02	Ayakta Durma
37331090	8,02	2,56	-6,16	Araç Kullanma
37331122	8,24	2,98	-6,66	Araç Kullanma
37331139	8,23	3,05	-6,47	Araç Kullanma
37331188	7,98	2,83	-6,35	Araç Kullanma
75814768	2,37	1,29	-0,79	Koşma
75814784	0,13	2,27	-0,64	Koşma
75814818	-0,58	4,55	-0,55	Koşma
75814848	-0,45	5,65	-0,53	Koşma
29068868	6,58	19,95	-6,07	Yürüme
29068899	5,86	16,40	-9,84	Yürüme
29068916	3,06	6,19	-7,93	Yürüme
29068947	2,54	20,26	-1,94	Yürüme

Veri toplamak için geliştirilen uygulamadan sonra verinin nerede ve ne şekilde toplanması gerektiği konusuna karar verilmesi gerekmektedir. Ayrıca araştırmaların gerçekleştirilmesi adına erkek ve kadın olmak üzere iki gruptan veri toplanmasına ihtiyaç duyulmaktadır. Çizelge 3.2’de gösterilen karakteristik özelliklere sahip üç kadın ve üç erkek tarafından veriler toplamaya başlanmıştır.

Çizelge 3.2. Veri seti oluşturan kişilerin karakteristik özellikleri

	Yaş	Kilo	Boy	Cinsiyet	Bilekte	Cepte
Ömer	30	125	1.83	Erkek	✓	✓
Turgay	25	85	1.82	Erkek	-	✓
İşıl	26	59	1.64	Kadın	-	✓
Fatma	28	70	1.71	Kadın	✓	✓
Ramazan	24	63	1.78	Erkek	-	✓
Ayşe	26	76	1.66	Kadın	-	✓

Veri setimiz kadın ve erkek fark etmeksizin bileğe takılı bir aparat içine yerleştirilen cep telefonu ile toplanmıştır. Ayrıca bir bay ve bir bayan tarafından hem bileğe takılan hem de pantolon cebine yerleştirilen cep telefonu eş zamanlı olarak veri toplama işlemini gerçekleştirilmiştir.



Şekil 3.4. Pantolon cebinde ve bileğe takılı telefonların taşıma şekli gösterilmektedir

3.3. Öznitelik Çıkarma

Veri toplama için geliştirmiş olduğumuz yazılımın toplamış olduğu ham verileri aşağıdaki öznitelik değerlerini kullanarak öznitelikli veri seti oluşturulmuştur. Bu işlemi gerçekleştirirken her 200 kayıttan yeni bir öznitelik kaydı oluşturulmuştur. Eğer herhangi bir aktiviteye ait kayıt sayısı 180'den az ise öznitelik üretimi yapılmamıştır. Yeni oluşturulan her bir kayıt, Çizelge 3.3'de gösterildiği gibi üretilen öznitelik değerleri ve aktivite türünden meydana gelmektedir.

Çizelge 3.3. Ham veriye öznitelikler uygulandıktan sonra oluşan öznitelikli veri seti

ort_x	ort_y	Ort_z	enkucuk_x	enkucuk_y	enkucuk_z	...	enbuyuk_x	enbuyuk_y	enbuyuk_z	kor_xy	kor_xz	kor_yz	aktivite
2.7	9.7	-0.1	10.1	2.3	9.6	...	-0.2	2.4	9.7	-0.3	0.2	-0.4	Yürüme
3.4	9.5	-0.1	10.1	3.3	9.4	...	-0.1	2.5	9.5	-0.2	0.4	-0.5	Yürüme
3.5	9.4	-0.1	10.1	3.4	9.3	...	-0.3	2.6	9.4	-0.3	0.2	-0.4	Yürüme
3.5	9.5	-0.1	10.1	3.6	9.6	...	-0.2	2.4	9.7	-0.2	0.2	-0.4	Yürüme
3.5	9.5	-0.2	10.1	3.5	9.6	...	-0.1	3.1	9.7	-0.3	0.3	-0.4	Yürüme
3.5	9.4	-0.2	10.1	3.4	9.3	...	-0.3	3.4	9.7	-0.3	0.2	-0.5	Yürüme
3.5	9.4	-0.2	10.1	3.3	9.3	...	-0.2	3.2	9.6	-0.5	0.3	-0.6	Yürüme
3.5	9.4	-0.2	10.1	3.4	9.2	...	-0.3	3.1	9.3	-0.2	0.3	-0.4	Yürüme
3.5	9.4	-0.1	10.1	3.6	9.4	...	-0.1	3.2	9.4	-0.2	0.2	-0.5	Yürüme
3.6	9.4	-0.1	10.1	3.5	9.4	...	-0.2	3.1	9.1	-0.9	0.5	-0.5	Yürüme
3.6	9.4	-0.1	10.1	3.5	9.3	...	-0.2	2.4	9.1	-0.5	0.5	-0.6	Yürüme
3.6	9.4	-0.3	10.1	3.3	9.2	...	-0.3	2.5	9.4	-0.4	0.4	-0.5	Yürüme
3.7	9.4	-0.3	10.1	3.5	9.6	...	-0.4	2.3	9.5	-0.5	0.4	-0.6	Yürüme
3.7	9.4	-0.3	10.1	3.6	9.3	...	-0.3	2.3	9.3	-0.4	0.4	-0.5	Yürüme
3.6	9.4	-0.1	10.1	3.5	9.3	...	-0.1	3.1	9.6	-0.3	0.3	-0.5	Yürüme
3.6	9.4	-0.1	10.1	3.4	9.4	...	-0.4	3.1	9.5	-0.3	0.4	-0.3	Yürüme
3.6	9.5	-0.7	10.1	3.4	9.4	...	-0.3	3.2	9.5	-0.3	0.4	-0.3	Yürüme
3.5	9.5	-0.7	10.1	3.4	9.4	...	-0.2	3.2	9.7	-0.4	0.4	-0.6	Yürüme
3.4	9.5	-0.7	10.1	3.6	9.3	...	-0.2	2.6	9.7	-0.6	0.6	-0.8	Yürüme
3.5	9.5	-0.7	10.1	3.5	9.6	...	-0.3	2.6	9.2	-0.4	0.5	-0.6	Yürüme
3.6	9.4	-0.7	10.1	3.5	9.5	...	-0.4	2.5	9.2	-0.8	0.8	-0.9	Yürüme
3.4	9.4	-0.1	10.1	3.3	9.5	...	-0.2	2.4	9.2	-0.5	0.5	-0.6	Yürüme
3.7	9.4	-0.8	10.1	3.4	9.3	...	-0.3	2.4	9.7	-0.4	0.4	-0.4	Yürüme

3.3.1. Ortalama

Her eksen için ivme değerlerinin ortalaması alınır. Aşağıdaki formül x, y ve z eksenlerine uyguladığımızda üç değer elde ederiz. Burada özellik sayımızda üç olmaktadır.

$$\sum_{i=1}^n \left(\frac{x_i}{n} \right) \quad (3.1)$$

Burada n kayıt sayısı x_i, y_i, z_i ivmeölçer değerlerini göstermektedir. Veri setimize ortalama özelliğini uyguladığımızda Çizelge 3.3'de örnek olarak gösterilen şekilde bir sonuç elde etmekteyiz.

3.3.2. Ortalama büyüklük

Sırasıyla her eksendeki ivme değerlerinin karesi alınarak toplanır. Elde etmiş olduğumuz sayının karekökünün ortalamasını aldığımızda bir adet değer elde edilir. Burada özellik sayımızda bir olmaktadır.

$$\sum_{i=1}^n \sqrt{x_i^2 + y_i^2 + z_i^2} / n \quad (3.2)$$

3.3.3. En küçük değer

Her eksendeki en küçük ivme değeri alınır. Burada üç adet değer elde edilir ve özellik sayımızda üç olmaktadır.

$$\min(x), \min(y), \min(z) \quad (3.3)$$

3.3.4. En büyük değer

Her eksenindeki en büyük ivme değeri alınır. Burada üç adet değer elde edilir ve özellik sayımızda üç olmaktadır.

$$\max(x), \max(y), \max(z) \quad (3.4)$$

3.3.5. Standart sapma

Her eksenindeki ivme değeri ile ortalama değer arasındaki farkın kareleri alınır. Çıkan değerlerin ortalaması bize standart sapmayı vermektedir. Burada üç adet değer elde edilir ve özellik sayımızda üç olmaktadır.

$$\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.5)$$

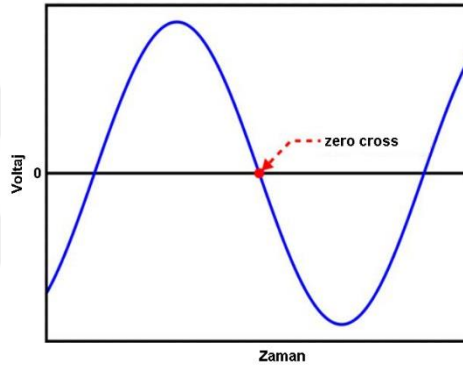
3.3.6. Mutlak ortalama fark

Her eksenindeki ivme değeri ile ortalama değer arasındaki farkın mutlak değeri hesaplanır. Çıkan sonucun ortalaması bize mutlak ortalama farkı verir. Burada üç adet değer elde edilir ve özellik sayımızda üç olmaktadır.

$$\frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| \quad (3.6)$$

3.3.7. Zero cross

Herhangi bir sinyalin sıfır değerine ulaşması sonucunda istenilen işlemin tetikleme durumu için böyle bir tespit yapılır. Sesle ilgili kullanım alanına bir örnek olarak radyo veya MP3 playerda müzik dinlerken sesi yükselttiğimizde tam sesi yükselttiğimiz anda kullanılan kelimelerde bozulma gerçekleşir. Bu bozulmanın önlenmesi için sıfır noktasında tetikleme yapılır. Ses yükseltme işlemi sıfır bu noktada yapıldığından anlık olarak kulağa hoş gelmeyecek sesler oluşmaz.




Şekil 3.5. Zero cross sıfır noktasında istenen işlemin tetiklenmesi yapılıır

Aktivite tanımada özellikle geçişlerin tespiti buna örnek gösterilebilir. Her eksenindeki ivme işaretindeki değişim sayısı alınır. Burada üç değer elde edilir ve özellik sayımızda üç olmaktadır.

3.3.8. Korelasyon

Korelasyon, istatistik ve olasılık kuramında iki rassal değişken arasındaki doğrusal ilişkinin gücünü ve yönünü gösterir. İstatistiksel kullanımda genel korelasyon, bağımsızlık durumundan ne kadar mesafe uzaklaşıldığını gösterir. Değişkenlerin arasındaki ilişki durumu, korelasyon katsayısı ile hesaplanmaktadır. Hangi korelasyon katsayısının kullanılacağı; Burada değişkenlerin hangi ölçek düzeyinde ölçülmüş

olmalarına, deęişkenlerin sürekli veya süreksiz olmalarına ve verilerin doğrusal olup olmamalarına göre deęişmektedir.



Şekil 3.6. Korelasyon deęişkenler arası ilişki türleri gösterilmiştir

Her eksenin birbiri arasındaki doğrusal bağımlılığın kuvveti alınır. Burada üç adet deęer elde edilir ve özellik sayımızda üç olmaktadır.

$$\frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (x_i - \bar{x})^2}} \quad (3.7)$$

3.4. Verileri Sınıflandırmada Kullanılan Yöntemler

Bu çalışmada ivmeölçer verilerinden elde edilen büyük boyuttaki veri setinin analiz edilmesinde “scikit-learn” adı verilen Python kütüphanesi kullanılmıştır.

Verilerin sınıflandırılmasında oluşturmuş olduğumuz programda yer alan K-en yakın komşu (kNN), Nâive Bayes (NB), Rastgele Orman (RO) ve Destek Vektörü Makineleri (SVM) yöntemleri kullanılmıştır. Kullanılan bu yöntemler aşağıda alt başlıklar halinde açıklanmıştır.

3.4.1. K-en yakın komşu

Makina öğrenmesinin en temel yöntemi olan K-en yakın komşu (kNN) yönteminde, test kümesinden alınan bir örneği sınıflandırmak için, bu örneğin eğitim kümesindeki her bir örnek ile arasındaki mesafe hesaplanır. Daha sonra k tane en küçük mesafeli eğitim kümesi örneği seçilir ve bu örneklerde en sık görülen etiket, test örneğinin etiketi olarak belirlenir. Eğitim kümesinden alınan örnek ile test kümesinden alınan örnekler arasında yapılan vektörel hesaplamalar aşağıda gösterildiği gibi Euclidean, Manhattan, Edit, Chebyshev gibi mesafe fonksiyonlarından seçilen biri tarafından yapılmaktadır.

Euclidean:

$$\sum_{i=1}^k (x_i - y_i)^2 \quad (3.8)$$


Manhattan:

$$\sum_{i=1}^k |x_i - y_i| \quad (3.9)$$

Minkowski:

$$\left(\sum_{i=1}^k (|x_i - y_i|)^q \right)^{1/q} \quad (3.10)$$

Hesaplanan mesafelere göre örnekler bir örnek uzayında Şekil 3.7’de görüldüğü gibi bir koordinat düzleminde bulunur. Seçilen k değerine göre sınıfı bilinmeyen örneğe en yakın k noktaya bakılarak “oylama” tekniği ile en fazla sayıda sınıf etiketi örneğin sınıf etiketi olarak belirlenir (Vinodhini *et al.* 2013).

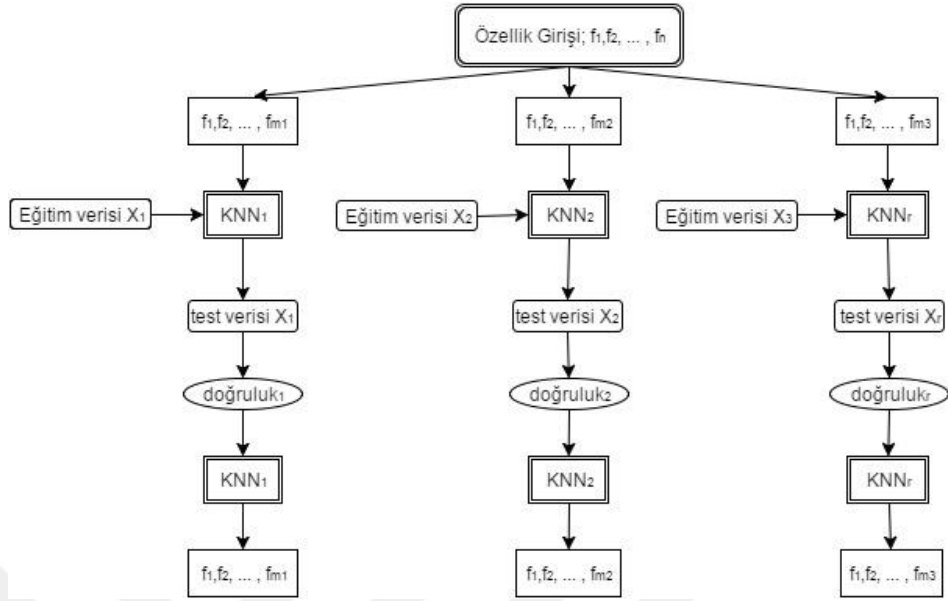


Şekil 3.7. K-en yakın komşu (kNN) yöntemi (Anonymous 2012)

Şekil 3.7 üzerinden K-en yakın komşu yöntemi anlatılırsa; yıldız ile gösterilen örnek sınıfı bilinmeyen ve k değerine göre belirlenecek olan örnektir. k değeri 3 olarak belirlendiğinde yıldız örneğine en yakın mesafede olan 1 sarı ve 2 mor yuvarlak şeklinde gösterilen örneğin sınıfı, yıldız örneğin de sınıfı olarak belirlenmektedir. k değeri 6 verildiğinde, iki adet mor yuvarlak örneği ile dört adet sarı yuvarlak örneğinin yer aldığı sınıfa bakılır.

Sınıflandırma yöntemlerinin performans değerlendirmesinde sadece doğruluk değil çalışma süresi de büyük önem taşımaktadır. Bir algoritmanın çalışma süresi, zaman karmaşıklığı olarak ifade edilmektedir. Bir programın zaman açısından performansını değerlendirmek için karmaşıklık ölçütlerinden en kötü durum işletim süresi (Worst-case Running Time) – O notasyonu yaygın olarak kullanılmaktadır.


K-en yakın komşu yönteminde d boyutlu bir örnek uzayında, n adet veri sayısında en yakın komşu verinin sınıfının bulunma süresi $O(d*n)$ olarak hesaplanmaktadır. Şekil 3.8’de K-en yakın komşu yöntemi akış diyagramı gösterilmektedir.



Şekil 3.8. K-en yakın komşu yöntemi akış diyagramı

3.4.2. Nâive Bayes (NB)


Olasılıksal sınıflandırma yöntemlerinden biri olan Nâive Bayes yöntemi, etiketi bilinen (sınıflandırılmış) örnek verilerini kullanarak etiketi bilinmeyen örnek verinin varolan sınıflardan birine ait olma olasılığını hesaplar. Tüm örnekler aynı derecede öneme sahip olup bir özelliğin değeri diğer bir öznelik değeri hakkında herhangi bir bilgi içermemektedir (Karakoyun ve Hacıbeyoğlu 2014).



Şekil 3.9. Nâive Bayes sınıflandırıcısı oldukça başarılı bir sınıflandırıcıdır

Doğrusal (A) ve doğrusal olmayan (B) şeklinde gösterilmiştir. iki farklı sınıf için rastgele örnekler renkli küre olarak gösterilirken, noktalı çizgiler sınıflandırıcıların karar

sınırlarını hesaplayarak yaklaşık bir değer vermeye çalıştıkları sınıf sınırlarını göstermektedir. Doğrusal (A) olan problem Nâive Bayes gibi doğrusal sınıflandırıcıların, ayrılabilir olduklarından dolayı uygun durum olacaktır. Fakat doğrusal olmayan problemlerde doğrusal olmayan sınıflandırıcılar (örnek tabanlı en yakın komşu sınıflandırıcılar) tercih edilmelidir (Domingos *et al.* 1997).



Şekil 3.10. Nâive Bayes yöntemi kullanılarak Doğrusal A'nın Doğrusal olmayan B probleminden daha iyi sonuç alacağı görülmektedir

İvmeölçerden gelen veriler üzerinde Nâive Bayes yöntemi uygulandığında; sınıf etiketi C olan her F_i özelliğinin şartlı olasılık değeri elde edilen eğitim verisinden öğrenilir. Yani, C sınıf etiketi, F değerleri ise ivmeölçer değeri olmak üzere;

$$P(C | F_1, F_2, \dots, F_n) = \frac{P(C) P(F_1, F_2, \dots, F_n | C)}{P(F_1, F_2, \dots, F_n)} \quad (3.11)$$

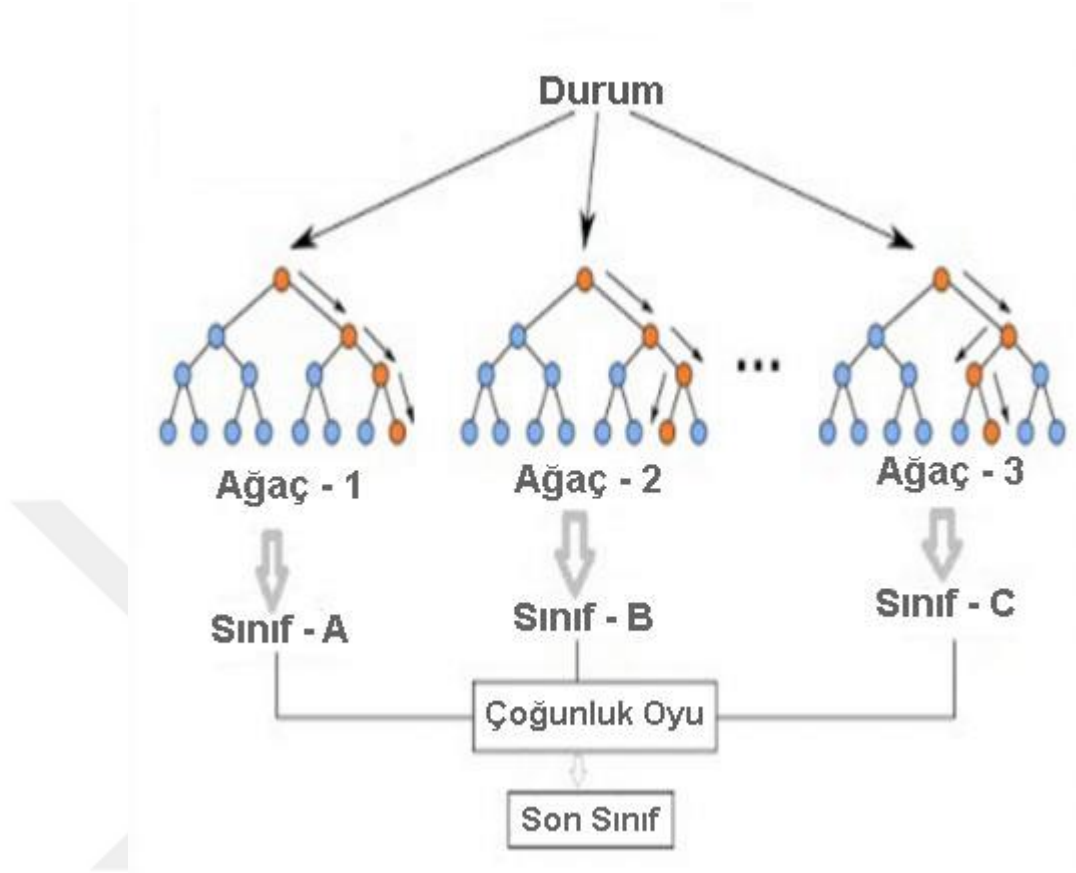
işlemi ile sınıfı bilinmeyen bir verinin C sınıfına ait olma olasılığı bulunur. Verinin C sınıfına ait olma olasılığı, o sonuca etki eden tüm faktörlerin sonucu sağlama olasılıklarının çarpımı sonucunda elde edilir. Olasılık hesapları sonucunda verinin ait olduğu sınıf ona, en yüksek olasılık değerini veren sınıf olarak belirlenir (Vinodhini *et al.* 2013).

Näive Bayes yönteminde n eğitim örneği sayısı ve v öznitelik sayısı olmak üzere zaman karmaşıklığı $O(n*v)$ olarak hesaplanmaktadır.

3.4.3. Rastgele orman

Ağaç yapılı sınıflandırıcıların toplamından oluşan rastgele orman yöntemi, ağaç topluluğunda bulunan ve kullanıcı tarafından belirlenen k adet ağaçtan her ağaç üzerinde giriş vektörünü inceleyerek giriş vektöründen yeni nesneyi sınıflandırır. Her ağaç, sınıflandırma sonucunda verilen giriş vektöründe bir birim oy ataması yapar. Bu yöntemde ormandaki tüm ağaçlar üzerinden en çok oya sahip sınıflandırma seçilir (Guo *et al.* 2004).

Ağaç topluluğu oluşturulurken; eğitim veri setindeki n adet örnek sayısı n sayıda durumla rastgele olarak yer değiştirerek ağaç oluşturmaktadır. Her düğümde m tahminleyici, M adet giriş değerlerinden rastgele seçilir ($m < M$) ve bu m tahminleyici üzerinde en iyi bölme, düğümü ayırmak için kullanılır (Guo *et al.* 2004). Bu m değeri ormanın büyümesi sırasında sabit tutulur. En iyi dallanma kriteri, gini indeksi ile hesaplanır ve hesaplanan değere göre veri seti her düğümde iki dala ayrılır (Akman vd 2011). En yakın optimal değerlere ulaşmak için varsayılan m değeri M sayısının karekökü olarak belirlenmiştir ($m = \sqrt{M}$). Her ağaç, mümkün olan en geniş ölçüde budama işlemi olmadan büyür.



Şekil 3.11. Ağaç topluluğu oluşturulurken; eğitim veri setindeki N adet örnek sayısı N sayıda durumla rastgele olarak yer değiştirilerek ağaç oluşturmaktadır

Mevcut ağaç için eğitim seti, yer değiştirme ile örnekleme yoluyla oluşturulduğunda, durumların yaklaşık üçte biri örnek dışında bırakılır. Dışarıda kalan veriler sınıflandırma hatasını tahmin etmek için test seti olarak kullanılır. Bu yüzden test verisinin hata oranını tahmin etmek için bir test veri setine veya katlamalı bölme yöntemlerine ihtiyaç yoktur.

Test işlemi dışarıda kalan bu veriler üzerinden tarafsız yapılır. Test işlemi esnasında tüm ağaçların, ayrılan bu test verisi ile test edilerek hata oranları hesaplanır. Daha sonra bu hata oranlarının ortalaması alınarak karar ormanının hatası hesaplanır. Karar ormanının hata oranına göre tüm ağaçlara ağırlık verilir. Hata oranı ile ağaca verilen ağırlık değeri ters orantılı olarak işlenmektedir. Belirlenen ağırlıklara göre en yüksek oya sahip ağaç, sınıf tahmini olarak belirlenir (Akman vd 2011).

Rastgele orman yönteminin mevcut sınıflandırma yöntemleri ile karşılaştırıldığında daha doğru sonuçlar vermesi, büyük boyutlu veri setleri üzerinde etkili bir şekilde çalışabilmesi, kayıp verilerin tahmini için etkili bir yöntem olması ve verilerin büyük bir kısmı eksik olduğunda doğruluğunu koruması, sınıflandırma için önemli olan özellikleri tahmin edebilmesi ve diğer yöntemlere göre gürültüye karşı güçlü olması gibi birçok özelliğinden dolayı popüler bir sınıflandırma yöntemidir.


Budanmamış bir karar ağacının tamamını oluşturmak için gerekli zaman karmaşıklığı $O(v * n \log(n))$ şeklindedir. Burada n , kayıt sayısı iken v , öznitelik sayısıdır. Karar ağaçlarından oluşan rastgele orman yönteminde ise oluşturmak istenilen ormandaki ağaç sayısı (n_{tree}) ve her düğümde kaç tane değişkenin örnekleneceği (m_{try}) önemlidir. Her düğümde örneklenecek değişken sayısı hesaba katıldığında bir ağacın zaman karmaşıklığı $O(m_{try} * n \log n)$ olmaktadır.

Çok sayıda ağacın oluşturulması için elde edilen zaman karmaşıklığı ise $O(n_{tree} * m_{try} * n \log(n))$ 'dir. En kötü durum analizinde ağacın derinliğinin $O(\log n)$ olacağı varsayıldığında çoğu durumda ağacın oluşturulma süreci bu süreden önce gerçekleşir ve bu süreyi tahmin etmek zordur. Rastgele orman yönteminde ağacın derinliği belirli bir miktarda sınırlandırılabilir. Ağaç derinliği kullanıcı tarafından maksimum p seviyesinde sınırlandırıldığında elde edilen zaman karmaşıklığı $O(n_{tree} * m_{try} * p * n)$ şeklindedir.

3.4.4. Destek vektör makineleri

Sınıflandırma yöntemleri arasında kullanılan oldukça etkin bir yöntemdir. Bu yöntemde bir şekilde bulunan iki ayrı grup arasında çizgi çizilerek iki grubu birbirinden ayırmak mümkündür. Sınırın çizilmesi gereken yer gruplarda bulunan üyelere uzak olan yer seçilmelidir. İşte destek vektör makineleri (Support Vector Machines-SVM) yukarıda anlatılan sınırın ne şekilde çizilmesi gerektiğini belirler.

Anlatılan işlemin yapılması için gruplara yakın aynı zamanda birbirine paralel iki belirleyici çizgi çizilir. Bu sınır çizgileri gittikçe birbirine yaklaştırmak suretiyle ortak sınır çizgisi oluşturulur. Örnek olarak ekil 3.12’de gösterildiği gibi iki grubu ele alalım:



Şekil 3.12. İki çizgiye paralel sınır çizilip ortak sınır çizgisi iki paralel çizgisi arasında üretilir

İki grup aynı düzlem üzerinde gösterilmiştir. Bu düzlemi öznitelik olarak düşünebiliriz. Genel anlamda sisteme giriş yapan her girdinin bir öznitelik çıkarımı (feature extraction) yapılmıştır. Her girişin gösterildiği farklı bir nokta düzlemde oluşturulmuştur. Gösterilen noktaların sınıflandırılması, üretilmiş olan özelliğe göre girişlerin gruplandırılması diyebiliriz.

Yukarıda sınıfların arasında oluşan mesafeye tolerans denilir. Gösterilen düzlemdeki noktaların tanımı aşağıdaki formül ile hesaplanabilir:

$$D = \{(x_i, c_i) | x_i \in R^p, c_i \in \{-1, 1\}\}_{i=1}^n \quad (3.12)$$

Yukardaki gösterimi incelediğimizde her c, x için X vektör uzayında bir nokta ve c ise bu noktanın $+1$ veya -1 şeklinde gösteren işlemdir. Buradaki noktalar kümesi $i=1$ 'den

n'e kadar devam eder. Bu gösterim önceki şekilde olan noktaların tümünü ifade etmektedir.

İlgili formülün belirtilmiş düzlem (hyperplane) üstünde bulunduğunu düşünürsek. Gösterimdeki her bir noktanın:

$$wx - b = 0 \quad (3.13)$$

yukardaki denklemlerle gösterilmesi mümkündür. Formüldeki w aşırı düzleme dik olan vektörü iken x noktanın değişken değeri ve b ise kayma oranıdır. Bu denklemi $ax+b$ doğru denklemine benzetebiliriz.


Tekrardan üstteki formüle baktığımızda $b/\|w\|$, iki çizgi arasındaki mesafenin farkını verir. Oluşan farka daha önce tolerans (offset) ismiyle göstermiştik. Bu mesafe farkı denkleme göre mesafeyi en yüksek değere çıkarmak için yukarıdaki ilk şekilde gösterilen 0, -1 ve +1 değerlerine sahip üç doğruyu veren denklemlerde $2/\|w\|$ formülü kullanılmıştır. Genel olarak iki çizgi arası mesafe iki birim olarak değerlendirilmiştir. Bu denkleme göre oluşan iki doğru denklemleri aşağıdadır:

$$wx - b = -1 \quad (3.14)$$

$$wx + b = 1 \quad (3.15)$$

olarak gözlemlenmektedir. Detaylı baktığımızda bu denklemler çizgilerle oluşturulmuş doğruların kaydırılmasında elde edilen en yüksek değerlerin belirlenmesi işleminin bir sonucudur.

İki grup arasındaki aşırı düzlemin (hyperplane) tek yönlü olması mümkün değildir. Örnek olarak aşağıda durum gösterilebilir:



Şekil 3.13. İki çizgi boyunca aşırı düzlemin tek yönlü olması imkansızdır

Şekil 3.14'e baktığımızda iki farklı düzlem bulunmasına rağmen SVM yönteminde bu olasılıklardan en büyük toleransa (offset) sahip olan değer alınır.

3.5. Performans Ölçütleri

Üst bölümde anlatılan yöntemler uygulanarak sınıflandırma yaptığımızda ortaya çıkan başarı oranını hesaplamak için kullanılacak standart ölçütler doğruluk oranı, keskinlik, duyarlılık ve F-ölçütüdür.

Çizelge 3.4'de kullanılan TN, FN, TP, FP değerleri sırasıyla aşağıdaki şekilde tanımlanır;

- FP (False Positive): Pozitif olan fakat sınıflandırıcı tarafından pozitif olmayanların sayısını gösterir.

- TP (True Positive): Pozitif olan aynı ve sınıflandırıcı tarafından da pozitif olanların değerlerini gösterir.
- FN (False Negative): Negatif olan fakat sınıflandırıcı tarafından negatif olmayanların değerlerini gösterir.
- TN (True Negative): Negatif olan aynı şekilde sınıflandırıcı tarafından da negatif olanların değerlerini gösterir.

Çizelge 3.4'de işaretleme sonucunda ya pozitif ya da negatif bir durum seçilmiştir. Örneğin eğitim verimiz aktivite tarafından toplamış olduğumuz verilerden oluşsun ve hangi durum olumlu hangisi olumsuz olduğunu tahmin etmeye çalışalım. Bu durumda olumlu aktivite tahminleri için pozitif olumsuz tahminler için negatif işaretlemiş olsun. Makine öğrenmesi metodundan elde edilen modelin amacı hem pozitifleri hem de negatifleri tahmin edebilmektir.

Çizelge 3.4. Karışıklık matrisi genel formu

Karışıklık Matrisi		Tahmin Sınıfı	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	TP	FN
	Negatif	FP	TN

Eğer var olan durum negatif ve tahmin negatif ise TN bir tahmin yapılmıştır. Yani yanlış bir durum yanlış olarak doğru bir şekilde tahmin edilmiştir. Eğer tahmin işleminde normalde pozitif olan bir durum pozitif olarak tahmin ediliyorsa TP bir tahmin yapılmıştır. Eğer var olan durum pozitif ise ve tahminci negatif olarak tahmin ederse FN ikinci tip hata oluşur. Eğer var olan durum negatif ise ancak tahmin sistemi pozitif olarak tahmin ederse birinci tip hata FP durumu oluşur.

3.5.1. Doğruluk (Accuracy)

Sınıflandırma işleminde en çok kullanılan ve basit olan ölçümdür. Doğru sınıflandırılmış örnek sayısının (TP+TN), toplam örnek sayısına (TP+TN+FP+FN) oranıdır.

$$\text{Doğruluk} = \frac{(TN + TP)}{(TN + FN + FP + TP)} \quad (3.13)$$

Bu değer bir'e tamamlayıcı *Hata oranıdır*. Başka bir deyişle yanlış sınıflandırılmış örneklerin sayısı (FN+FP), örneklerin toplam sayısına (TN+TP+FN+FP) bölünmesidir.

$$\text{Hata Oranı} = \frac{(FN + FP)}{(TN + FN + FP + TP)} \quad (3.14)$$

3.5.2. Kesinlik (Precision)

Sınıflandırıcı sonucunun kesinlik derecesini verir. Kesinlik, sınıfı bir olarak tahmin edilmiş True Pozitif (TP) örnek sayısının, sınıfı bir olarak tahmin edilmiş tüm örnek sayısına (TP+FP) oranıdır.

$$\text{Kesinlik} = \frac{TP}{(FP + TP)} \quad (3.15)$$

3.5.3. Duyarlılık (Recall)

Doğru olarak sınıflandırılmış olan pozitif örnek (TP) sayısının, pozitif örneklerin toplamında oluşan sayıya (FN+TP) oranıdır.

$$\text{Duyarlılık} = \frac{TP}{(FN + TP)} \quad (3.16)$$

3.5.4. F-Ölçütü (F-Measure)

Duyarlılık ve kesinlik ölçütleri yalnız başlarına düzgün bir sonuç elde etmemiz için yeterli değildir. Bu iki ölçütü beraber kullanmak doğru sonuçlar ulaşma imkânı verir. Bu beraber kullanım için f-ölçütü (F) belirlenmiştir. Matematiksel tanımlar ise K-ölçütü, duyarlılığın (D) ve kesinlik (K) harmonik ortalamasıdır. Sistemin, duyarlılık ve ya kesinlik tarafına doğru optimize işlemi yapılır.

$$\mathbf{F - Ölçütü} = \frac{2KD}{(K + D)} \quad (3.17)$$

4. ARAŞTIRMA BULGULARI

Materyal ve yöntemler bölümünde ayrıntılı bir şekilde anlatmış olduğumuz aktivite tanıma işlemi kapsamında iki veri seti oluşturulmuştur.

Birinci veri seti üç erkek, üç kadın olmak üzere altı kişiyi kapsamaktadır. Veri toplama bölümünde anlatıldığı gibi altı kişiden toplanmış olan bu veriler bileğe takılı bir cep telefon aracılığıyla gerçekleştirilmiştir.

İkinci veri seti ise bir erkek ve bir kadından oluşmak üzere iki kişiyi kapsamaktadır. Veri toplama işlemi aynı aktiviteleri gerçekleştirirken hem bileğe takılı bir telefon, hem de pantolon cebinde olan cep telefon aracılığıyla aynı anda oluşturulmuştur.

Yöntemlerimizde k-fold cross validation yöntemi kullanılmıştır. Makine öğrenmesi çalışmalarında, uygulanan yöntemin başarı sınaması yapılması için, veri kümesini eğitim ve test kümeleri olarak ayırmaktadır. Bu ayırma işlemi çeşitli şekillerde yapılabilir. Örneğin veri setinin %70'lik bir kısmını eğitim %30'luk bir kısmını ise test verisi olarak ayırdıktan sonra eğitim kümesiyle sistem eğitildikten sonra test kümesi ile başarının oranını bulabiliriz.

K-katlamalı çarpaz doğrulam yönteminde öncelikle bir k değeri seçilir. Elimizdeki veri seti seçmiş olduğumuz k değeri kadar eşit parçaya bölünür. Örnek olarak elimizde beş yüz kayıt var ve biz k değerini on kabul edersek 50'şer eşit parçaya ayrılır ve bu şekilde çalışmaya başlar.

Öncelikle parçalardan birisi test için seçilip geri kalanı eğitim için kullanılacaktır. Burada hangi parçadan başlandığının bir önemi yoktur. İlk on parçayı test için seçip diğer parçaları eğitim için kullanmaya karar verildiği düşünülürse. En baştan başlayarak tüm bölümlerde kullanmış olduğumuz sınıflandırma yöntemini uygular. Sonuç olarak döngü adeti kadar bir değer elde edilir. Sistemin genel başarısı veya genel hatası (error

rate) ise, elde edilen bu sonuçların ortalaması olarak hesaplanıyor. Bu son adımda ortalama alındığı için ve ortalama hesaplanırken kullanılan toplama işleminin yer değiştirme özelliği olduğu için, hangi parçadan başlandığının bir önemi yoktur.

$$\text{Sonuç} = \frac{\sum_{i=0}^k SF(t_i, VK - t_i)}{k} \quad (4.1)$$

Buradaki $SF(\text{test}, \text{eğitim})$ sınıflandırma fonksiyon, VK veri kümesi, k kaç parça katlama kullanıldığı ve t ise veri kümesi üzerinden seçilen her bir test kümesi olarak verilmiştir. Yukarıda formülize edildiği üzere, sonuç bütün sınıflandırma fonksiyonlarının performanslarının toplamının, k sayısına bölünerek ortalamasının alınmasıdır.

Araştırma boyunca kullanılan sınıflandırma yöntemlerinin parametreleri Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Sınıflandırma yöntemlerinde kullanılan parametrelerin varsayılan değerleri

Algoritma	Varsayılan Değer
kNN	k=1
	mesafe= Öklit Mesafesi
SVM	c= 1.0
	çekirdek=PolyKernel
	tolerans=0.001
	$\epsilon=1.0E-12$
NB	alpha=1.0
RO	ağaç sayısı=50 ölçüt=mse

Çalışma boyunca veri setleriyle yapmış olduğumuz çalışmalar aşağıda üç alt başlıkta listelenmiştir.

- Genel sınıflandırma performansı
- Bay ve bayan farkının incelenmesi
- Cep telefonun taşınma pozisyonuna etkisi

4.1. Genel Sınıflandırma Performansı

Öznitelik çıkarma bölümünde anlatılan yirmi iki öznitelik kullanılarak birinci veri setinden üretilmiş öznitelik veri setine NB, RO, kNN ve SVM sınıflandırma yöntemleri uygulanmıştır. Elde edilmiş olan sonuçlar Çizelge 4.2’de kişi bazlı gösterilmektedir.

Çizelge 4.2. Bilekliğe oluşturulan altı kişiye ait veri setlerine uygulanan aktivite tanıma yöntemlerinin doğru tahmin yüzdeleri

	SVM	NB	RO	KNN
Ömer	82,4	98,5	99,6	98,5
Tugay	82,3	97,6	99,1	94,4
Işıl	81,3	96,3	97,4	90,4
Fatma	80,1	94,2	94,5	91,9
Ramazan	79,5	93,2	93,4	92,2
Ayşe	79,0	95,2	92,1	88,5
Ortalama	80,8	95,8	96,0	92,6

Çizelgede en yüksek doğru tahmin yüzdesine sahip yöntem RO yöntemi olurken en iyi sonuç %99,6 doğruluk oranıyla Ömer’den oluşturulan veri seti olmuştur. Rastgele orman yöntemini kişi bazlı değerlendirdiğimizde sırasıyla Ömer, Tugay, Işıl, Fatma, Ramazan ve Ayşe yüksekten düşüğe doğru sıralandığı görülmektedir.

Genel olarak RO yöntemi en yüksek, SVM ise en düşük tahmin oranını vermektedir. Bu durum Kırkan ve arkadaşlarının bildirisinde de gözlemlenmiştir. Genel anlamda RO yönteminin diğer yöntemlere oranla daha başarılı olmuştur.

Çizelge 4.3. Işıl'ın bileğe takılı cep telefonu ile topladığı veri seti sonuçlarına göre en iyi yöntem olan RO'nın karışıklık matrisi gösterilmiştir. Birbirleriyle en çok karıştırılan aktivitelerin sayısı kutu içerisinde gösterilmiştir

	Tahmin Edilen Aktivite									
		Ayakta Durma	Oturma	Uzanma	Yürüme	Yemek Yeme	Merdiven Çıkma	Merdiven İnme	Araba Sürme	Koşma
Ayakta Durma	99	0	0	0	0	0	1	0	0	0
Oturma	0	294	2	0	1	0	0	0	3	0
Uzanma	0	3	226	0	0	0	0	0	1	0
Yürüme	0	0	0	396	0	0	0	0	1	3
Yemek Yeme	0	2	0	0	117	0	0	0	1	0
Merdiven Çıkma	0	0	0	0	0	78	2	0	0	0
Merdiven İnme	0	0	0	0	0	10	80	0	0	0
Araba Sürme	0	3	0	0	2	0	0	0	180	0
Koşma	1	0	0	5	0	0	0	0	0	89

Bu deney için aynı incelemede ortaya çıkan karışıklık matrisi Çizelge 4.3'te gösterilmektedir. Bu matris incelendiğinde aşağıdaki aktivite ikililerinin **en çok** birbirleri ile karıştırıldıkları görülmektedir.

- Merdiven Çıkma / Merdiven İnme
- Yürüme / Koşma
- Oturma / Uzanma
- Oturma / Araba Kullanma

Bu aktivitelerin benzer hareketleri barındırması nedeniyle benzer aktiviteler olduğu ve bu yüzden birbirine karıştırılabileceği açıktır.

Kırkan ve arkadaşlarının telefonu *pantolon cebinde* taşıyarak elde ettikleri sonuçlarla, bu sonuçlar karşılaştırıldığında; yapmış olduğumuz çalışma genel olarak %5-%10 aralığında daha iyi tahminleme oranına ulaştığı gözükmektedir. Farkın genel anlamda cep telefon pozisyonundan kaynaklandığı düşünülmektedir. Bu yorumu doğrulamak için ek deneyler yapılmış ve elde edilen sonuçlar bölüm 4.3'te (Cep telefonun taşınma pozisyonunun etkisi) anlatılmıştır (Kırkan *et al.* 2015).

4.2. Erkek ve Kadın Farkının İncelenmesi

Bu incelemede üç erkek ve üç kadından oluşan veri setimiz ve seçtiğimiz öznitelikler kullanılarak bay ve bayanların ayrıştırılabilir olup olmadığı incelenmiştir.

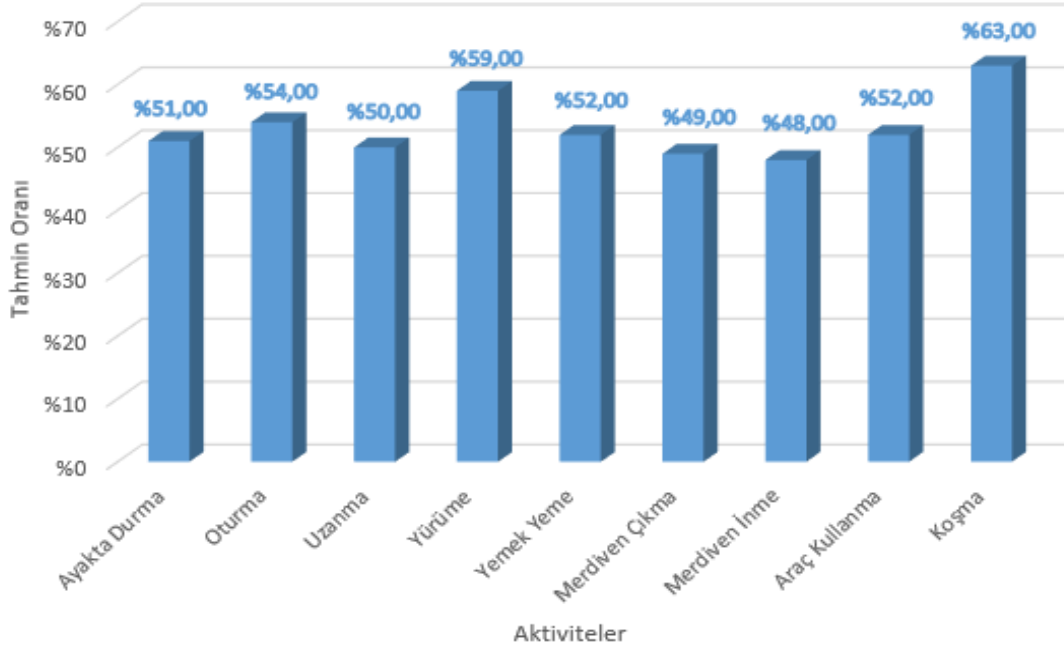
Oluşturmuş olduğumuz birinci veri setimizde bulunan erkek ve kadınların aktivite bazlı tüm verileri ayrıştırılmıştır. Ayrıştırılan verilerden aynı aktiviteleri birleştirerek ayrı dosyalar oluşturulmuş olup bu dosyalar yeni sınıflandırma problemi için öznitelik veri seti olarak kullanılmıştır. Bu işlemler yapıldıktan sonra her bir aktivite için ayrı bir veri seti olacak şekilde dokuz ayrı veri seti oluşturulmuştur. Örneğin üç erkek ve üç kadına ait bütün koşma aktivitelerini tek bir dosyaya yazarak koşma veri seti elde edilmiştir.

Oluşan bu yeni veri setlerindeki değerler erkek ve kadın verileri olarak iki kategoride işaretlenmiştir. Bu yöntemle oluşturulan koşma veri setinin bir kısmı örnek olarak aşağıdaki Çizelge 4.4’de gösterilmiştir.

Çizelge 4.4. Üretilen öznelik veri setinin bir kısmı gösterilmektedir. Öznelik değerleri yerden tasarruf etmek amacıyla yuvarlanmıştır. Veri sütununda karşılık gelen özneliklerin detaylı açıklamaları bölüm 3.3’de detaylı bir şekilde verilmiştir.

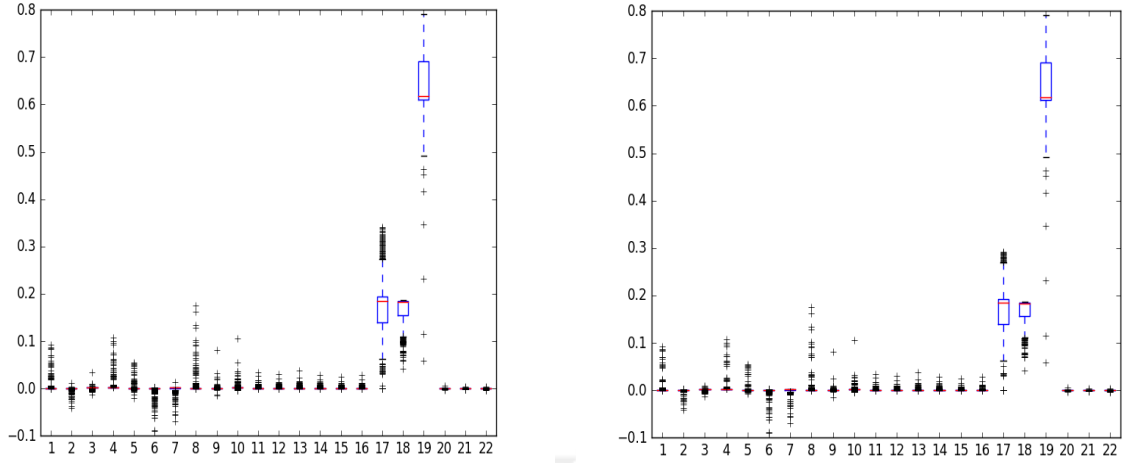
ort_x	ort_y	Ort_z	enkucuk_x	enkucuk_y	enkucuk_z	...	enbuyuk_x	enbuyuk_y	enbuyuk_z	kor_xy	kor_xz	kor_yz	cinsiyet
2.7	9.7	-0.1	10.1	2.3	9.6	...	-0.2	2.4	9.7	-0.3	0.2	-0.4	Erkek
3.4	9.5	-0.1	10.1	3.3	9.4	...	-0.1	2.5	9.5	-0.2	0.4	-0.5	Kadın
3.5	9.4	-0.1	10.1	3.4	9.3	...	-0.3	2.6	9.4	-0.3	0.2	-0.4	Erkek
3.5	9.5	-0.1	10.1	3.6	9.6	...	-0.2	2.4	9.7	-0.2	0.2	-0.4	Kadın
3.5	9.5	-0.2	10.1	3.5	9.6	...	-0.1	3.1	9.7	-0.3	0.3	-0.4	Erkek
3.5	9.4	-0.2	10.1	3.4	9.3	...	-0.3	3.4	9.7	-0.3	0.2	-0.5	Erkek
3.5	9.4	-0.2	10.1	3.3	9.3	...	-0.2	3.2	9.6	-0.5	0.3	-0.6	Erkek
3.5	9.4	-0.2	10.1	3.4	9.2	...	-0.3	3.1	9.3	-0.2	0.3	-0.4	Kadın
3.5	9.4	-0.1	10.1	3.6	9.4	...	-0.1	3.2	9.4	-0.2	0.2	-0.5	Kadın
3.6	9.4	-0.1	10.1	3.5	9.4	...	-0.2	3.1	9.1	-0.9	0.5	-0.5	Erkek
3.6	9.4	-0.1	10.1	3.5	9.3	...	-0.2	2.4	9.1	-0.5	0.5	-0.6	Erkek
3.6	9.4	-0.3	10.1	3.3	9.2	...	-0.3	2.5	9.4	-0.4	0.4	-0.5	Kadın
3.7	9.4	-0.3	10.1	3.5	9.6	...	-0.4	2.3	9.5	-0.5	0.4	-0.6	Erkek
3.7	9.4	-0.3	10.1	3.6	9.3	...	-0.3	2.3	9.3	-0.4	0.4	-0.5	Erkek
3.6	9.4	-0.1	10.1	3.5	9.3	...	-0.1	3.1	9.6	-0.3	0.3	-0.5	Kadın
3.6	9.4	-0.1	10.1	3.4	9.4	...	-0.4	3.1	9.5	-0.3	0.4	-0.3	Erkek
3.6	9.5	-0.7	10.1	3.4	9.4	...	-0.3	3.2	9.5	-0.3	0.4	-0.3	Kadın
3.5	9.5	-0.7	10.1	3.4	9.4	...	-0.2	3.2	9.7	-0.4	0.4	-0.6	Erkek
3.4	9.5	-0.7	10.1	3.6	9.3	...	-0.2	2.6	9.7	-0.6	0.6	-0.8	Kadın
3.5	9.5	-0.7	10.1	3.5	9.6	...	-0.3	2.6	9.2	-0.4	0.5	-0.6	Erkek
3.6	9.4	-0.7	10.1	3.5	9.5	...	-0.4	2.5	9.2	-0.8	0.8	-0.9	Erkek
3.4	9.4	-0.1	10.1	3.3	9.5	...	-0.2	2.4	9.2	-0.5	0.5	-0.6	Kadın
3.7	9.4	-0.8	10.1	3.4	9.3	...	-0.3	2.4	9.7	-0.4	0.4	-0.4	Erkek

Çizelge 4.5. RO yöntemi kullanılarak veri setimizde işaretlemiş olduğumuz erkek ve kadınların aktivite bazında tahmin oranları



Oluşan dokuz adet veri setine RO, NB, SVM ve kNN yöntemleri uygulanmış ve en yüksek tahmin oranının RO yöntemi olduğu gözlemlenmiştir. RO Yöntemi kullanılarak elde edilen doğru tahmin yüzdeleri Çizelge 4.5'te gösterilmektedir.

Tahmin oranlarının genel olarak %50 civarında olması ve en yüksek başarımın %63 civarında olması kullanılan öznelikler ve uygulanan sınıflandırma yöntemleriyle erkek/kadın aktivite ayrımının yapılamadığı gösterilmektedir. Bu durum erkek ve kadın için öznelik değerlerinin incelemesi ile daha iyi anlaşılabilir. Şekil 4.1'deki yürüme aktivitesinde örnek birer erkek ve kadın (Ömer ve Işıl) için öznelik değerleri gösterilmektedir.



Şekil 4.1. Ömer (Sol) ve Işıl'a (sağ) ait yürüme aktivitesine ait verilerin öznitelik değerleri birbirlerine çok yakın gözükmektedir

Şekilde birden yirmi ikiye kadar öznitelik değerleri verilmiş olup bu öznitelikler öznitelik çıkarma bölümünde detaylıca anlatılmıştır.

Şekil 4.1'deki öznitelik değerlerine bakıldığında bu değerlerin birbirlerine çok yakın olduğu görülmektedir. Bu sebepten dolayı belirtilmiş olan öznitelikler kullanılarak erkek-kadın ayrımının gerçekleştirilemediği düşünülmektedir.

4.3. Cep Telefonun Taşınma Pozisyonunun Etkisi

Daha önce bölüm 4.1'de bahsedildiği üzere Kırkan ve arkadaşlarının çalışması incelenmişti. Bizim çalışmalarımız ile Kırkan ve arkadaşlarının yapmış oldukları çalışma karşılaştırıldığında bölüm 4.1 yapılan çalışmanın daha başarılı sonuçlar vermesinin cep telefonu pozisyonundan kaynaklandığı tahmin edilmişti. Bu tahminden yola çıkarak cep telefonu pozisyonunun etkisini daha doğru görebilmek amacıyla aynı anda hem bilekte hem de pantolon cebinde cep telefonu taşıyarak aynı aktiviteler için yeni bir veri seti oluşturulmasına karar verildi. Bu veri setinde iki kişiyle her iki cep telefonu pozisyonu kullanılarak aynı anda iki cep telefon ile ölçüm gerçekleştirilmiştir.

Pantolon cebinde taşınan telefondan ve bileğe takılı olarak taşınan telefondan almış olduğumuz ham verilerin üst bölümlerde anlatıldığı gibi özellik çıkarma, sınıflandırma yöntemlerinin uygulanması vb. aşamalardan geçirilerek sonuçlarının incelemesi yapılmıştır.

Oluşturulan veri aynı yöntemler ile incelendikten sonra elde edilen tahmin oranları Çizelge 4.6'da gösterilmiştir.

Çizelge 4.6. Sınıflandırma yöntemleri uyguladıktan sonra Ömer ve Fatma'nın bilek ve cep sonuçları

	SVM		NB		RO		KNN	
	Bilek	Cep	Bilek	Cep	Bilek	Cep	Bilek	Cep
Ömer	81,3	74,3	96,2	71,5	97,4	91,3	97,3	85,4
Fatma	80,1	71,2	90,5	70,2	97,4	89,5	95,5	82,3
Ortalama	80,7	72,8	93,3	70,8	97,4	90,4	96,4	83,9

Veriler aynı anda toplanmasına rağmen bilekte taşınan cep telefonundan elde edilen verilerle elde edilen tahmin oranının %5-%7 daha fazla olduğu görülmektedir.


Çizelge 4.7'de gösterilen değerler incelendiğinde yürüme, koşma, merdiven çıkma ve merdiven inme aktivitelerinin, telefon bileğe takılı iken %7 - %10 daha yüksek doğruluk oranına eriştiği görülmektedir.

Çizelge 4.7. RO yöntemi kullanılarak aktivite bazlı Ömer ve Fatma'ya ait bileğe takılı telefon ve cepte bulunan telefon verilerinin karşılaştırılması

Aktivite	Bilek		Cep	
	Ömer	Fatma	Ömer	Fatma
Ayakta Durma	99,5	99,2	94,3	93,6
Oturma	98,9	98,4	95,7	94,1
Uzanma	99,6	99,8	94,9	93,1
Yürüme	99,6	96,9	90,1	89,7
Yemek Yeme	94,8	96,3	91,5	86,6
Merdiven Çıkma	94,3	95,4	88,6	88,7
Merdiven İnme	93,9	94,6	86,8	86,5
Araba Sürme	99,8	98,9	94,2	93,7
Koşma	98,6	99,1	90,1	88,3

Kol hareketliliğinin diğer aktivitelerden daha az olduğu oturma ve uzanma aktivitelerini incelediğimizde ise bileğe takılı telefonda elde edilen veri setinden oluşan sonuçların, cepte oluşana göre %3- %5 daha başarılı doğruluk oranına eriştiği görülmektedir.

Genel olarak iki gruba ayırdığımız bu aktiviteler arasındaki doğruluk oranı farkının kol hareketliliğinden kaynaklandığını söyleyebiliriz. Örneğin Çizelge 4.7'de bulunan Ömer veri setinin yürüme aktivitesini incelersek bilekte %99,6 iken eş zamanlı oluşturulmuş cep veri setinde doğruluk oranı %90,1 olup aralarındaki fark %9,5 olmuştur. Yürüme aktivitesinden çok daha az hareketliliğe sahip olan oturma aktivitesine baktığımızda aradaki fark %3,2 olarak gözlemlenmektedir. Bu durum bileğe giyilen akıllı telefonun kol hareketliliğinden dolayı pantolon cebinde olan akıllı telefonda daha yüksek doğruluk oranına ulaştığını göstermektedir.



Şekil 4.2. Koşma aktivitesi yapılırken yürüme aktivitesine göre kollar daha çok açılı olarak hareket eder

Sonuç olarak tüm bu veriler incelendiğinde kolların koşma, yürüme, yemek yeme vb. aktivitelerde aktif bir şekilde hareket ettiğini görmekteyiz. Bu hareketlerden dolayı ayırt edici noktalar daha kolay öne çıkmaktadır. Örneğin Şekil 4.2’de görüldüğü gibi koşma aktivitesini gerçekleştirirken kollar vücuda 90 derecelik açı ile belirli bir tempoda ileri geri hareket ederken yürüme aktivitesinde kollar vücuda paralel bir şekilde 90 dereceden daha az bir açı ile hareket etmektedir. İki aktivite birbirine yakın olmasına karşın hareketler arasında oluşan bu fark ayırt edici özellik olarak sınıflandırma yöntemleri tarafında kullanılarak daha doğru tahmin oranlarına erişmeye neden olabilmektedir.

5. SONUÇ ve ÖNERİLER

Bu çalışmada, akıllı telefonda elde edilen ivmeölçer verileri kullanılarak dokuz farklı aktivitenin doğru tanınması amaçlanmıştır. Aktivite seçimi sırasında günlük hayatta sıkça tekrarlanan aktiviteler tercih edilmiştir. Aktivite tanıma işlemi, herkesin sahip olduğu ve günümüzde yaygın olarak kullandığı akıllı cep telefonları ile yapılarak günlük hayatta kullanılabilir bir uygulama gerçekleştirilmiştir. Aktivitelerden elde ettiğimiz ham verilerin öznitelik veri setine dönüşümünde yirmi iki öznitelik kullanılmış olup oluşturulan bu öznitelikli veriler dört ayrı sınıflandırma yöntemiyle tahminleme oranları tespit edilmiştir. Çalışma sonucu aşağıdaki üç temel başlıktan oluşturulmuştur.

- Genel sınıflandırma performansı
- Erkek ve kadın farkının incelenmesi
- Cep telefonun taşıma pozisyonuna etkisi

Genel performans olarak dokuz aktiviteye ait öznitelik değerlerinden oluşan veri kümesi ile yapılan aktivite tanıma çalışmasında, %99,6 doğruluk oranı ile rastgele orman en başarılı yöntem olurken merdiven inme ve merdiven çıkma aktiviteleri birbirlerine benzedikleri için en çok karıştırılan aktiviteler olmuştur.

Bay ve bayan arasında ayırt edici öznitelikler saptamak için aktivite bazlı veri seti oluşturulmuş olup veri setinde bay ve bayanlar işaretlenerek sınıflandırma yöntemlerine tabi tutulmuştur. İşaretlenmiş olan bu veri setlerinin birbirlerine çok yakın değerler verdiği görülmüştür. Oluşan bu yakın değerlerde özniteliklerin bu anlamda yeterince ayırt edici öznitelikler olmadığı tespit edilmiştir.

Vücut hareketleri düşünüldüğünde seçmiş olduğumuz aktivitelerin birçoğunda el hareketleri ayırt edici öznitelik olarak ön plana çıkmaktadır. Genel performansın yüksek olmasının bilekte elde edilen veriden kaynaklandığı düşünülerek eş zamanlı olarak hem pantolon cebinde, hem de bilekteki telefonda veri setleri oluşturulmuş olup bu işlemde

bilekte toplanan veri pantolon cebinde toplanan veriden daha iyi sonuca ulařtıđı ortaya çıkmıřtır.

Gelecek alıřmalarımızda merdiven inme ve merdiven ıkma aktivitelerinin birbirlerinden ayırt edilmesini sađlamak amacıyla farklı algılayıcılardan elde edilen yeni zniteliklerin kullanılması planlanmaktadır. Ayrıca kadın/erkek iin ayırt edici znitelikler bulup kiři ayırımını yapılabilecek dzeye ulařtırmak planlarımız arasındadır. Yapmıř olduđumuz alıřmada bilekte tařıman telefonun iyi sonu verdiđi grlmřtr. Fakat cep telefonun bileđe takılması gndelik hayata yapılması zor bir iřlemdir. Bu anlamda yapmıř olduđumuz alıřmalarımızı řuan kullanılan yaygın giyilebilir cihazlara ynelik geliřtirmekte diđer bir planımızdır.

KAYNAKLAR

- Brdiczka, O., M. Langet, J. Maisonnasse, and J. L. Crowley, "Detecting human behavior models from multimodal observation in a smart home," *Automation Science and Engineering, IEEE Transactions*, vol. 6, no. 4, pp. 588–597, 2009.
- Brémond, F., M. Thonnat, and M. Zuniga, "Video-understanding framework for automatic behavior recognition," *Behavior Research Methods*, vol. 38, no. 3, pp. 416–426, 2006.
- Brendel, W. A. Fern, and S. Todorovic, "Probabilistic event logic for interval-based event recognition," In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference*, IEEE, 2011, pp. 3329–3336.
- Chang, M., -C. N. Krahnstoeber, S. Lim, and T. Yu, "Group level activity recognition in crowded environments across multiple cameras," In *Advanced Video and Signal Based Surveillance (AVSS), 2010 Seventh IEEE International Conference*, 2010, pp. 56– 63.
- Chen, D., A. J. Bharucha, and H. D. Wactlar, "Intelligent video monitoring to improve safety of older persons," In *Engineering in Medicine and Biology Society, 2007, EMBS 2007, 29th Annual International Conference of the IEEE*, IEEE, 2007, pp. 3814–3817.
- Direkolu C. and N. E. OConnor, "Team activity recognition in sports," In *Computer Vision–ECCV 2012, Springer Berlin Heidelberg*, 2012, pp. 69–83,
- Fleury, A., M. Vacher, and N. Noury, "Svm-based multimodal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results," *Information Technology in Biomedicine, IEEE Transactions*, vol. 14, no. 2, pp. 274–283, 2010.
- Foroughi, H., A. Naseri, A. Saberi, and H. S. Yazdi, "An eigenspacebased approach for human fall detection using integrated time motion image and neural network," In *Signal Processing, 2008, ICSP 2008, 9th International Conference*, IEEE, 2008, pp. 1499–1503.
- Fosty, B., C. F. Crispim-Junior, J. Badie, F. Bremond, M. Thonnat *et al.*, "Event recognition system for older people monitoring using an rgb-d camera," In *ASROB-Workshop on Assistance and Service Robotics in a Human Environment*, 2013.
- Gencer, C., Akbulut, S., Kızılkaya Aydoğan, E. (2008), Churn Analysis And Customer Segmentation Of A Cosmetics Brand Using Data Mining Techniques, *Journal of Engineering and Natural Sciences, Sigma*. Vol./Cilt 26 Issue/Sayı 1.
- Goldstone, J., A. "The new population bomb: the four megatrends that will change the world," *foreign affairs*, pp. 31–43, 2010.
- Gomez C., and J. Paradells, "Wireless home automation networks: A survey of architectures and technologies," *Communications Magazine, IEEE*, vol. 48, no. 6, sf. 92 –101, 2010.
- Huynh, D., T. G. "Human Activity Recognition with Wearable Sensors," PhD thesis, TU Darmstadt, 2008.

- Karakoyun, M., ve Hacıbeoğlu, M. 2014. Biyomedikal Veri Kümeleri ile Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. DEU Mühendislik Fakültesi Mühendislik Bilimleri Dergisi, 16 (48), 30-42
- Kırkan, S., Işıl Karabey ve Levent Bayındır Pantolon cebinde taşınan akıllı telefonun ivmeölçer verilerini kullanarak aktivite tanıma. Mühendislikte yeni teknolojiler MYT/Bayburt,2015
- Kwapisz, J., R. G. M. Weiss, and S. A. Moore, “Activity recognition using cell phone accelerometers,” ACM SigKDD Explorations Newsletter, 2011, vol. 12, no. 2, pp. 74–82.
- Lara O.D., and Labrador M. A. “A Survey on Human Activity Recognition using Wearable Sensors”, IEEE Communication Surveys & Tutorials, vol. 15, no. 3, pp. 1192-1209, 2013
- Lien, J., M. G. Kurillo, R. Bajcsy, “Multi-camera tele-immersion system with real-time model driven data compression,” The Visual Computer 26, 3-15, 2010.
- Machot, F., Al, K. Kyamakya, B. Dieber, and B. Rinner, “Real time complex event detection for resource-limited multimedia sensor networks,” In Advanced Video and Signal-Based Surveillance (AVSS), 8th IEEE International Conference, 2011, pp. 468-473.
- Maurer, U., A. Smailagic, D. P. Siewiorek, and M. Deisher, “Activity recognition and monitoring using multiple sensors on different body positions,” In Wearable and Implantable Body Sensor Networks, 2006, BSN 2006, International Workshop, IEEE, 2006, pp. 4-pp.
- Nievas, E., B. O. D. Suarez, G. B. Garcia, and R. Sukthankar, “Violence detection in video using computer vision techniques,” In Computer Analysis of Images and Patterns, Springer Berlin Heidelberg, 2011, pp. 332-339.
- Okeyo, G., L. Chen, H. Wang, “Combining ontological and temporal formalisms for composite activity modelling and recognition in smart homes,” Future Generation Computer Systems, vol. 39, no. 0, pp. 29–43, 2014.
- Shotton, J. *et al.*, “Real-time human pose recognition in parts from single depth images,” Communications of the ACM 56, no. 1, pp. 116-124, 2013.
- Tang, K., L. Fei-Fei, and D. Koller, “Learning latent temporal structure for complex event detection,” In Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference, IEEE, 2012, pp. 1250-1257.
- Theekakul, P., S. Thiemjarus, E. Nantajeewarawat, T. Supnithi and K. Hirota, “A rule-based approach to activity recognition,” In Knowledge, Information, and Creativity Support Systems, Springer Berlin Heidelberg, 2011, pp. 204-215. 21
- Touati, R., and M. Mignotte, “Mds-based multi-axial dimensionality reduction model for human action recognition,” In Computer and Robot Vision (CRV), 2014 Canadian Conference, IEEE, 2014, pp. 262–267.
- Vacher, M., *et al.*, “Evaluation of a context-aware voice interface for Ambient Assisted Living: qualitative user study vs. quantitative system evaluation,” ACM Transactions on Accessible Computing (TACCESS), vol. 7, no. issue 2, pp. 1-36, 2015.
- Vacher, M., *et al.*, “The Sweet-Home speech and multimodal corpus for home automation interaction,” The 9th edition of the Language Resources and Evaluation Conference (LREC), 26-31 May, 2014, Reykjavik, Iceland, pp. 4499-4506.

- Van, C.i, Rijsbergen, Information Retrieval, 2nd edition. Dept. of Computer Science, University of Glasgow, 1979
- Viani, F., M. Martinelli, L. Ioriatti, L. Lizzi, G. Oliveri, P. Rocca, and A. Massa, "Real-time indoor localization and tracking of passive targets by means of wireless sensor networks," In Antennas and Propagation Society International Symposium, 2009, APSURSI'09, IEEE, 2009, pp. 1-4.
- Wang, W., A.X. Liu, M. Shahzad, K. Ling, and S. Lu, "Understanding and modeling of WiFi signal based human activity recognition," In Proceedings of the 21st Annual International Conference on Mobile Computing and Networking, ACM, September 2015, pp. 65-76.
- Weinland, D., R. Ronfard, and E. Boyer, "A survey of vision-based methods for action representation, segmentation and recognition," Computer Vision and Image Understanding, vol. 115, no. 2, pp. 224-241, 2011.



ÖZGEÇMİŞ

Ömer OKUCU 1987 yılında Ağrı'da doğdu. İlk, orta ve lise öğrenimini Ağrı'da tamamladı. 2007-2012 yılları arasında Sakarya Üniversitesi Bilgisayar Mühendisliği bölümünde lisans derecesini aldı. Mezuniyetinin ardından 2014 yılında Atatürk Üniversitesi'nde yüksek lisans eğitimine başladı. Özel bir firmada yazılım ağırlıklı AR-GE faaliyetleri gerçekleştirmektedir.

