

**T.C.**  
**MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**AKILLI CİHAZ ALGILAYICILARI İLE AKTİVİTE VE**  
**ULAŞIM TÜRÜ TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**ENSAR ARİF SAĞBAŞ**

**ARALIK 2016**

**MUĞLA**

**T.C.**  
**MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**AKILLI CİHAZ ALGILAYICILARI İLE AKTİVİTE VE**  
**ULAŞIM TÜRÜ TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**ENSAR ARİF SAĞBAŞ**

**ARALIK 2016**

**MUĞLA**

**MUGLA SITKI KOÇMAN ÜNİVERSİTESİ**  
**Fen Bilimleri Enstitüsü**

**TEZ ONAYI**

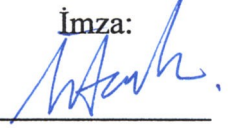
ENSAR ARİF SAĞBAŞ tarafından hazırlanan AKILLI CİHAZ ALGILAYICILARI İLE AKTİVİTE VE ULAŞIM TÜRÜ TESPİTİ başlıklı tezinin, 16.12.2016 tarihinde aşağıdaki jüri tarafından Bilişim Sistemleri Mühendisliği Anabilim Dalı'nda yüksek lisans derecesi için gerekli şartları sağladığı oybirliği ile kabul edilmiştir.

---

**TEZ SINAV JURİSİ**

Doç. Dr. Ayhan İSTANBULLU (**Jüri Başkanı**)  
Bilgisayar Mühendisliği Anabilim Dalı,  
Balıkesir Üniversitesi, Balıkesir

İmza:



Yrd. Doç. Dr. Serkan BALLI (**Danışman**)

İmza:

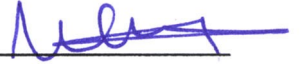
Bilişim Sistemleri Mühendisliği Anabilim Dalı,  
Muğla Sıtkı Koçman Üniversitesi, Muğla



Yrd. Doç. Dr. Musa PEKER (**Üye**)

İmza:

Bilişim Sistemleri Mühendisliği Anabilim Dalı,  
Muğla Sıtkı Koçman Üniversitesi, Muğla



---

**ANA BİLİM DALI BAŞKANLIĞI ONAYI**

Yrd. Doç. Dr. Hüseyin GÜRÜLER  
Bilişim Sistemleri Mühendisliği Anabilim Dalı Başkanı,  
Muğla Sıtkı Koçman Üniversitesi, Muğla

İmza:



Savunma Tarihi: 16.12.2016

---

Tez çalışmalarım sırasında elde ettiğim ve sunduğum tüm sonuç, doküman, bilgi ve belgelerin tarafımdan bizzat ve bu tez çalışması kapsamında elde edildiğini; akademik ve bilimsel etik kurallarına uygun olduğunu beyan ederim. Ayrıca, akademik ve bilimsel etik kuralları gereği bu tez çalışması sırasında elde edilmemiş başkalarına ait tüm orijinal bilgi ve sonuçlara atıf yapıldığını da beyan ederim.

Ensar Arif SAĞBAŞ

16.12.2016

**ÖZET**  
**AKILLI CİHAZ ALGILAYICILARI İLE AKTİVİTE VE ULAŞIM TÜRÜ**  
**TESPİTİ**

Ensar Arif SAĞBAŞ

Yüksek Lisans Tezi

Fen Bilimleri Enstitüsü

Bilişim Sistemleri Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Serkan BALLI

Aralık 2016, 104 sayfa

Hareket algılayıcılarından elde edilen veriler kullanılarak gerçekleştirilen aktivite sınıflandırma çalışmaları son yıllarda rağbet görmektedir. Bu çalışmalarda veriler hem insan vücuduna yerleştirilen giyilebilir algılayıcılar hem de akıllı cihazlardan elde edilmektedir. Bu tezde, sınıflandırma için iki farklı cihaz (akıllı telefon ve akıllı saat) kullanılmış ve üç ayrı sınıflandırma çalışması gerçekleştirilmiştir. Bunlar, akıllı telefon algılayıcı verileri kullanılarak insan hareketlerinin sınıflandırılması, akıllı telefon algılayıcı verileri kullanılarak ulaşım türü sınıflandırılması ve akıllı saat algılayıcı verileri kullanılarak insan hareketlerinin sınıflandırılmasıdır. Sınıflandırma için sınıflandırıcı toplulukları (AdaboostM1, Bagging, Rastgele alt uzaylar ve Oylama) ve makine öğrenmesi (Naive Bayes, kNN, Rastgele Orman ve C4.5) yöntemleri kullanılmış ve performansları karşılaştırılmıştır. Veri setini oluşturmak amacıyla, Android ve Android Wear tabanlı mobil uygulamalar geliştirilmiş ve kişi yürürken, koşarken, merdiven inerken ve çıkarken, asansör kullanırken, hareketsiz dururken, bisiklet sürerken, araba veya otobüs ile seyahat ederken akıllı telefonda, yazı yazarken (kâğıda, tahtaya ve klavye), yürürken, koşarken, temizlik yaparken (süpürge), diş fırçalarken ve hareketsiz durumdayken akıllı saatten algılayıcı verileri toplanmıştır. Değerlendirmeler sonucunda en başarılı algılayıcı kombinasyonu ve sınıflandırma yöntemi geliştirilen çevrimiçi eylem tanıma uygulamalarında kullanılmıştır.

Test sonuçlarına göre en yüksek doğruluk oranları akıllı telefon ile ulaşım türü sınıflandırması için ivmeölçer ve jiroskop algılayıcıları kullanılarak Bagging+kNN yönteminden, akıllı telefon ile insan hareketlerinin sınıflandırılması için GPS, ivmeölçer ve jiroskop algılayıcıları kullanılarak Rastgele Orman yönteminden, akıllı saat ile insan hareketlerinin sınıflandırılması için ivmeölçer, jiroskop, kalp hızı ve adımsayar algılayıcıları kullanılarak Bagging+kNN yönteminden elde edilmiştir. Sistem mimarileri ve deneysel sonuçlar örnekler üzerinde açıklanmış ve geliştirilen sistemlerinin nasıl iyileştirileceği tartışılmıştır.

**Anahtar Kelimeler:** Aktivite Sınıflandırma, Akıllı Saat, Akıllı Telefon, Algılayıcı Verileri, Makine Öğrenmesi, Sınıflandırıcı Toplulukları

**ABSTRACT**  
**ACTIVITY AND TRANSPORTATION MODE DETECTION WITH SMART  
DEVICE SENSORS**

Ensar Arif SAĞBAŞ

Master of Science (M.Sc.)

Graduate School of Natural and Applied Sciences

Department of Information Systems Engineering

Supervisor: Asst. Prof. Dr. Serkan BALLI

December 2016, 104 pages

Activity classification studies by using data obtained from motion sensors have been popular in recent years. In these studies, data are obtained from both wearable sensors placed on human body and smart devices. In this thesis, two different devices (smartphone and smartwatch) were used and three separate classification studies were carried out. These are human motion classification by using smartphone sensor data, transportation mode classification by using smartphone sensor data and human motion classification by using smartwatch sensor data. Ensemble classifiers (AdaboostM1, Bagging, Random Subspaces and Voting) and machine learning methods (Naive Bayes, kNN, Random Forest and C4.5) were used for classification and their performances were compared. In order to build the dataset, Android and Android Wear based mobile applications were developed and GPS, accelerometer and gyroscope sensor data were collected from smartphone while walking, running, ascending and descending stairs, using elevator, stationary, riding bicycle, travelling by bus or car, accelerometer, gyroscope, step counter and heart rate sensor data were collected from smartwatch while writing (on the paper, on the board and using keyboard), walking, running, cleaning (vacuuming), brushing teeth and stationary. As a result of evaluations, the most successful sensor combination and classification method were used in the developed online activity recognition applications.

According to the test results, the highest accuracy rates were obtained from Bagging ensemble of kNN method by using accelerometer and gyroscope sensors for human motion classification with smartphone; Random Forest method by using GPS, accelerometer and gyroscope sensors for transportation mode classification with smartphone; Bagging ensemble of kNN by using accelerometer, gyroscope, step counter and heart rate sensors for human motion classification with smartwatch. System architectures and experimental results with examples were explained and how to improve the developed systems was discussed.

**Keywords:** Activity Recognition, Smartwatch, Smartphone, Sensor Data, Machine Learning, Ensemble Classifiers

Sevgili Eşime

## ÖNSÖZ

Akademik düşünmenin ve çalışmanın temellerini öğrettiği ve yüksek lisans eğitimim süresince gerçekleştirdiğim bütün çalışmalarımın her alanında göstermiş olduğu yardımlar için tez danışmanım Yrd. Doç. Dr. Serkan Ballı'ya teşekkür ederim.

Ayrıca tez çalışmam süresince beni sabırla destekleyen sevgili eşim Zeynep Sağbaşı'a, hiçbir fedakârlıktan kaçınmayan annem Emine Sağbaşı ve babam Şefik Sağbaşı'a, sevgili ablam Betül Zeynep Yıldız ve eniştem Fevkani Yıldız'a sonsuz teşekkürlerimi sunarım.

Tez çalışmamın veri toplama aşamasında yardımlarını esirgemeyen arkadaşlarım Arş. Gör. Adil Çoban, Arş. Gör. Tahsin Çetin, Arş. Gör. Emine Yağız Gürbüz ve Hakan Keleş'e ayrıca şükranlarımı sunarım.

Son olarak tez çalışmasının bilimsel olarak sunulduğu dergiler ve konferanslarda yorumları ile çalışmamın gelişmesini sağlayan bilim insanlarına teşekkürü bir borç bilirim.

Bu tez çalışması, M.S.K.Ü BAP-16-061 numaralı Bilimsel Araştırma Projesiyle desteklenmiştir.



# İÇİNDEKİLER

<b>ÖNSÖZ</b> .....	<b>vii</b>
<b>İÇİNDEKİLER</b> .....	<b>viii</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>x</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>xiii</b>
<b>SEMBOLLER VE KISALTMALAR DİZİNİ</b> .....	<b>xv</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Amaç ve Kapsam .....	3
1.2. Türkiye ve Dünyada Aktivite Sınıflandırma ve Ulaşım Türü Tespiti ile İlgili Yapılan Çalışmalar .....	4
1.2.1. İnsan hareketlerinin akıllı telefon algılayıcıları ile tespit edilmesi ile ilgili literatürde yer alan çalışmalar .....	4
1.2.2. Ulaşım türü sınıflandırılması ile ilgili literatürde yer alan çalışmalar .....	8
1.2.3. İnsan hareketlerinin giyilebilir akıllı cihazlar veya insan vücuduna yerleştirilen algılayıcılar kullanılarak tespit edilmesi ile ilgili literatürde yer alan çalışmalar .....	10
<b>2. AKILLI CİHAZ ALGILAYICILARI</b> .....	<b>15</b>
2.1. GPS Algılayıcısı .....	15
2.2. İvmeölçer Algılayıcısı .....	17
2.3. Jiroskop Algılayıcısı .....	19
2.4. Adımsayar Algılayıcısı .....	21
2.5. Kalp Hızı Algılayıcısı .....	22
<b>3. SINIFLANDIRMA YÖNTEMLERİ</b> .....	<b>24</b>
3.1. Makine Öğrenmesi Yöntemleri .....	24
3.1.1. Naive Bayes .....	24
3.1.2. kNN (k En yakın komşu – k Nearest neighbor) .....	25
3.1.3. C4.5 .....	26
3.1.4. Rastgele Orman .....	27
3.2. Sınıflandırıcı Toplulukları .....	28

3.2.1. AdaBoostM1 .....	29
3.2.2. Bagging .....	29
3.2.3. Rastgele alt uzaylar (RAU) .....	30
3.2.4. Oylama .....	31
<b>4. AKTİVİTE SINIFLANDIRMA ve ULAŞIM TÜRÜ TESPİTİ İÇİN UYGULAMA GELİŞTİRİLMESİ .....</b>	<b>32</b>
4.1. İnsan Hareketlerinin Akıllı Saat Algılayıcıları ile Tespit Edilmesi .....	33
4.1.1. Veri seti .....	34
4.1.2. Öznitelik seçimi .....	36
4.1.3. Sınıflandırma işlemi ve deneysel bulgular .....	40
4.1.4. Akıllı saat için eylem tanıma mobil uygulaması geliştirilmesi.....	53
4.2. Ulaşım Türlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi.....	55
4.2.1. Veri seti .....	56
4.2.2. Öznitelik seçimi .....	57
4.2.3. Sınıflandırma işlemi ve deneysel bulgular .....	60
4.2.4. Ulaşım türü tespiti için mobil uygulama geliştirilmesi .....	71
4.3. İnsan Hareketlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi.....	72
4.3.1. Veri seti .....	73
4.3.2. Öznitelik seçimi .....	73
4.3.3. Sınıflandırma işlemi ve deneysel bulgular .....	75
4.3.4. Akıllı telefon için eylem tanıma için mobil uygulama geliştirilmesi.....	87
<b>5. SONUÇLAR .....</b>	<b>90</b>
<b>KAYNAKLAR .....</b>	<b>93</b>
<b>ÖZGEÇMİŞ.....</b>	<b>102</b>

## ÇİZELGELER DİZİNİ

Çizelge 4.1. Kalp hızı algılayıcısı veri aralığı.....	39
Çizelge 4.2. Çalışmada kullanılan algılayıcılar ve öznelilikler.....	39
Çizelge 4.3. Giriş değerlerine göre algılayıcı kombinasyonu model yapısı .....	40
Çizelge 4.4. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre doğruluk oranları .....	42
Çizelge 4.5. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar.....	43
Çizelge 4.6. Yöntemlere ve algılayıcı kombinasyonlarına göre ortalama F-ölçütü değerleri .....	44
Çizelge 4.7. Yöntemlere ve algılayıcı kombinasyonlarına göre eğri altında kalan ortalama alan.....	45
Çizelge 4.8. Naive Bayes yöntemine ait karmaşıklık matrisi .....	46
Çizelge 4.9. AdaboostM1+Naive Bayes yöntemine ait karmaşıklık matrisi .....	46
Çizelge 4.10. Bagging+Naive Bayes yöntemine ait karmaşıklık matrisi .....	46
Çizelge 4.11. RAU+Naive Bayes yöntemine ait karmaşıklık matrisi.....	47
Çizelge 4.12. kNN yöntemine ait karmaşıklık matrisi.....	47
Çizelge 4.13. AdaboostM1+kNN yöntemine ait karmaşıklık matrisi.....	48
Çizelge 4.14. Bagging+kNN yöntemine ait karmaşıklık matrisi .....	48
Çizelge 4.15. RAU+kNN yöntemine ait karmaşıklık matrisi .....	48
Çizelge 4.16. C4.5 yöntemine ait karmaşıklık matrisi .....	49
Çizelge 4.17. AdaboostM1+C4.5 yöntemine ait karmaşıklık matrisi.....	49
Çizelge 4.18. Bagging+C4.5 yöntemine ait karmaşıklık matrisi .....	49
Çizelge 4.19. RAU+C4.5 yöntemine ait karmaşıklık matrisi .....	50
Çizelge 4.20. Rastgele Orman yöntemine ait karmaşıklık matrisi.....	50
Çizelge 4.21. AdaboostM1+Rastgele Orman yöntemine ait karmaşıklık matrisi.....	51
Çizelge 4.22. Bagging+Rastgele Orman yöntemine ait karmaşıklık matrisi .....	51
Çizelge 4.23. RAU+Rastgele Orman yöntemine ait karmaşıklık matrisi .....	51
Çizelge 4.24. Oylama yöntemine ait karmaşıklık matrisi .....	52

Çizelge 4.25. Ulaşım türü tespiti çalışmasında kullanılan algılayıcılar ve öznitelikler .....	58
Çizelge 4.26. Giriş değerlerine göre algılayıcı kombinasyonu model yapısı .....	60
Çizelge 4.27. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre doğruluk oranları.....	61
Çizelge 4.28. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar .....	62
Çizelge 4.29. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri .....	63
Çizelge 4.30. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre eğri altında kalan ortalama alanlar .....	64
Çizelge 4.31. Naive Bayes yöntemine ait karmaşıklık matrisi .....	65
Çizelge 4.32. AdaboostM1+Naive Bayes yöntemine ait karmaşıklık matrisi .....	65
Çizelge 4.33. Bagging+Naive Bayes yöntemine ait karmaşıklık matrisi .....	65
Çizelge 4.34. Rastgele Alt Uzaylar+Naive Bayes yöntemine ait karmaşıklık matrisi .....	65
Çizelge 4.35. kNN yöntemine ait karmaşıklık matrisi .....	66
Çizelge 4.36. AdaboostM1+kNN yöntemine ait karmaşıklık matrisi.....	66
Çizelge 4.37. Bagging+kNN yöntemine ait karmaşıklık matrisi .....	66
Çizelge 4.38. Rastgele Alt Uzaylar+kNN yöntemine ait karmaşıklık matrisi .....	66
Çizelge 4.39. C4.5 yöntemine ait karmaşıklık matrisi .....	67
Çizelge 4.40. AdaboostM1+C4.5 yöntemine ait karmaşıklık matrisi.....	67
Çizelge 4.41. Bagging+C4.5 yöntemine ait karmaşıklık matrisi .....	67
Çizelge 4.42. Rastgele Alt Uzaylar+C4.5 yöntemine ait karmaşıklık matrisi .....	68
Çizelge 4.43. Rastgele Orman yöntemine ait karmaşıklık matrisi.....	68
Çizelge 4.44. AdaboostM1+Rastgele Orman yöntemine ait karmaşıklık matrisi.....	68
Çizelge 4.45. Bagging+Rastgele Orman yöntemine ait karmaşıklık matrisi .....	69
Çizelge 4.46. Rastgele Alt Uzaylar+Rastgele Orman yöntemine ait karmaşıklık matrisi .....	69
Çizelge 4.47. Oylama yöntemine ait karmaşıklık matrisi .....	69
Çizelge 4.48. Ulaşım türü tespiti çalışmasında kullanılan algılayıcılar ve öznitelikler .....	74
Çizelge 4.49. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre sınıflandırma doğruluk oranları .....	76
Çizelge 4.50. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar .....	77

Çizelge 4.51. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri .....	78
Çizelge 4.52. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre eğri altında kalan ortalama alanlar .....	79
Çizelge 4.53. Naive Bayes yöntemine ait karmaşıklık matrisi .....	80
Çizelge 4.54. AdaboostM1 + Naive Bayes yöntemine ait karmaşıklık matrisi .....	80
Çizelge 4.55. Bagging + Naive Bayes yöntemine ait karmaşıklık matrisi .....	80
Çizelge 4.56. Rastgele alt uzaylar + Naive Bayes yöntemine ait karmaşıklık matrisi .....	81
Çizelge 4.57. kNN yöntemine ait karmaşıklık matrisi .....	81
Çizelge 4.58. AdaboostM1 + kNN yöntemine ait karmaşıklık matrisi.....	82
Çizelge 4.59. Bagging + kNN yöntemine ait karmaşıklık matrisi .....	82
Çizelge 4.60. Rastgele alt uzaylar + kNN yöntemine ait karmaşıklık matrisi .....	82
Çizelge 4.61. C4.5 yöntemine ait karmaşıklık matrisi .....	83
Çizelge 4.62. AdaboostM1 + C4.5 yöntemine ait karmaşıklık matrisi.....	83
Çizelge 4.63. Bagging + C4.5 yöntemine ait karmaşıklık matrisi .....	83
Çizelge 4.64. Rastgele alt uzaylar + C4.5 yöntemine ait karmaşıklık matrisi .....	84
Çizelge 4.65. Rastgele Orman yöntemine ait karmaşıklık matrisi.....	84
Çizelge 4.66. AdaboostM1 + Rastgele Orman yöntemine ait karmaşıklık matrisi....	84
Çizelge 4.67. Bagging + Rastgele Orman yöntemine ait karmaşıklık matrisi .....	85
Çizelge 4.68. Rastgele alt uzaylar + Rastgele Orman yöntemine ait karmaşıklık matrisi .....	85
Çizelge 4.69. Oylama yöntemine ait karmaşıklık matrisi .....	86

## ŞEKİLLER DİZİNİ

Şekil 1.1. Aktivite tespiti işlemleri (Su vd., 2014).....	2
Şekil 2.1. Dünya yörüngesindeki GPS uyduları .....	15
Şekil 2.2. İki boyutta konumlandırma(Çınar, 2005) .....	17
Şekil 2.3. Akıllı telefon ivmeölçer algılayıcısı eksenleri .....	18
Şekil 2.4. Akıllı saat ivmeölçer algılayıcısı eksenleri .....	18
Şekil 2.5. Dünyanın dönüş hareketi (Ayabakan, 2014) .....	19
Şekil 2.6. Jiroskopun yapısı .....	20
Şekil 2.7. Akıllı telefon jiroskop algılayıcısı eksenleri .....	21
Şekil 2.8. Optik kalp hızı algılayıcısı yapısı .....	23
Şekil 3.1. Rasgele orman algoritması (Özkan ve Erol, 2015).....	28
Şekil 3.2. Oylama algoritmasının şeması (Kökçü vd., 2014).....	31
Şekil 4.1. Akıllı cihazlar ile insan hareketlerinin ve ulaşım türlerinin sınıflandırılması akış şeması.....	33
Şekil 4.2. Gerçekleştirilen insan hareketleri .....	34
Şekil 4.3. Çalışmada kullanılan akıllı saat .....	34
Şekil 4.4. Akıllı saat için geliştirilen veri seti uygulaması ekran görüntüleri .....	35
Şekil 4.5. Akıllı saat veri seti uygulaması yapısı .....	35
Şekil 4.6. Veri seti uygulaması akıllı telefon ekran görüntüsü .....	36
Şekil 4.7. Eylemlere göre örnek akıllı saat ivmeölçer algılayıcısı verileri .....	37
Şekil 4.8. Eylemlere göre akıllı saat jiroskop algılayıcısının X eksenini örnek verileri	37
Şekil 4.9. Eylemlere göre akıllı saat jiroskop algılayıcısının Y eksenini örnek verileri	37
Şekil 4.10. Eylemlere göre akıllı saat jiroskop algılayıcısının Z eksenini örnek verileri .....	38
Şekil 4.11. Eylemlere göre ortalama kalp atış hızları .....	38
Şekil 4.12. Eylemlere göre atılan ortalama adım sayısı.....	39
Şekil 4.13. Bagging+kNN yöntemine ait ROC eğrisi.....	53
Şekil 4.14. Akıllı saat için geliştirilen eylem tanıma uygulaması ekran görüntüsü...	54

Şekil 4.15. Tespit edilen hareketleri akıllı telefonda raporlayan uygulama ekran görüntüsü .....	55
Şekil 4.16. Çalışmada sınıflandırılan ulaşım türleri.....	55
Şekil 4.17. Çalışmada kullanılan akıllı telefon .....	56
Şekil 4.18. Akıllı telefon için geliştirilen veri seti uygulaması ekran görüntüsü.....	57
Şekil 4.19. Ulaşım türlerine göre örnek akıllı telefon ivmeölçer algılayıcısı verileri	58
Şekil 4.20. Ulaşım türlerine göre akıllı telefon jiroskop algılayıcısının X eksenini örnek verileri .....	59
Şekil 4.21. Ulaşım türlerine göre akıllı telefon jiroskop algılayıcısının Y eksenini örnek verileri .....	59
Şekil 4.22. Ulaşım türlerine göre akıllı telefon jiroskop algılayıcısının Z eksenini örnek verileri .....	59
Şekil 4.23. Bagging+kNN yöntemine ait ROC eğrisi.....	70
Şekil 4.24. Ulaşım türü sınıflandırma uygulaması çalışma senaryosu.....	71
Şekil 4.25. Sınıflandırma uygulaması ekran görüntüsü .....	72
Şekil 4.26. Gerçekleştirilen insan hareketleri .....	73
Şekil 4.27. Eylemlere göre örnek akıllı telefon ivmeölçer algılayıcısı verileri .....	74
Şekil 4.28. Eylemlere göre akıllı telefon jiroskop algılayıcısının X eksenini örnek verileri .....	74
Şekil 4.29. Eylemlere göre akıllı telefon jiroskop algılayıcısının Y eksenini örnek verileri .....	75
Şekil 4.30. Eylemlere göre akıllı telefon jiroskop algılayıcısının Z eksenini örnek verileri .....	75
Şekil 4.31. Rastgele Orman yöntemine ait ROC eğrisi.....	87
Şekil 4.32. İnsan hareketlerinin sınıflandırılması uygulamasının çalışma senaryosu	88
Şekil 4.33. Eylem tanıma uygulaması ekran görüntüsü.....	89

## SEMBOLLER VE KISALTMALAR DİZİNİ

GPS	Global Positioning System
kNN	k-Nearest Neighbor
PART	Pruning Rule Based Classification Tree
NNGE	Non-Nested Generalized Exemplars
CART	Classification and Regression Tree
PPG	Photoplethysmography
Weka	Waikato Environment for Knowledge Analysis
AUC	Area Under Curve
FM	F-Measure
RMSE	Root Mean Squared Error
NB	Naive Bayes
RAU	Rastgele Alt Uzaylar
RO	Rastgele Orman




# 1. GİRİŞ

İnsan aktivitelerinin ve ulaşım türlerinin algılayıcılar ile sınıflandırılması son on yılın güncel araştırma konuları arasında yer almaktadır (Köse vd., 2012). Bu çalışmalar sayesinde kişilerin günlük aktivite takipleri, düşme tespiti veya ne tür araç ile seyahat ettiğinin tespiti gerçekleştirilebilmektedir.

Günümüz akıllı cihazları geçmişe göre çok daha fazla dâhili algılayıcıya sahiptir. Kullanımı hızla artan giyilebilir algılayıcılar kullanıcıların günlük aktivitelerini gerçekleştirirken taşıyabildikleri küçük cihazlardır. Hareket hızı, konum değişimi ve hareket yönü gibi insanların fiziksel durumunu kaydedebilen ivmeölçer, jiroskop, barometre, mikrofon ve GPS gibi algılayıcılar bunlara örnek olarak gösterilebilir. Mevcut güncel akıllı telefon ve akıllı saatler bu algılayıcıları barındırmaktadırlar. (Guiry vd., 2014; Sağbaş ve Ballı, 2016a).

Günümüzde akıllı telefonlar insanların sürekli yanlarında taşıdıkları, kullanıcılarına telefon görüşmesinden daha fazlasını sunan cihazlar haline gelmiştir. Sahip olduğu algılayıcı verilerinin toplanması; sağlık, sosyal medya, taşıma, çevresel izleme ve güvenlik gibi çeşitli uygulamaların geliştirilebilmesini mümkün kılmaktadır (Lane vd., 2010). Bu algılayıcılar aynı zamanda konum tespitine ve ivme hesaplanmasına da olanak sağlamaktadırlar. Akıllı saatlerin rağbette olmasıyla bileğe takılabilen cihazlar kişisel sağlık takibinde önemli bir araç haline gelmiştir. Böylece akıllı telefonların ve akıllı saatlerin sahip olduğu algılayıcı verilerini kullanarak kişinin yapmış olduğu yürüme, koşma, bisiklet sürme, motorlu taşıt ile seyahat etme gibi gündelik aktivitelerin tespiti de mümkün olmaktadır (Reddy vd., 2008; Mortazavi vd., 2014). Şekil 1.1. akıllı cihaz algılayıcıları ile aktivite tespiti için genel işlemleri göstermektedir.



Şekil 1.1. Aktivite tespiti işlemleri (Su vd., 2014)

Aktivite tespiti birçok gerçek uygulama için önem taşımaktadır. İnsan bilgisayar etkileşimi ile alakalı, bilgisayarları daha akıllı yapacak bir örnek vermek gerekirse; akıllı cihaz kullanıcının odadan çıktığını tespit etmiş ve akıllı cihazdaki hava durumu uygulaması havanın yağışlı olacağı hakkında bir bilgiye sahip olsun. Bu durumda hatırlatma uygulaması bilgilendirme mesajı ile “Şemsiyeni yanına al. Büyük olasılıkla yağmur yağacak” bilgisini verebilir. Aktivite tespitinde bir diğer önemli uygulama, hem bina içinde hem de bina dışında yönlendirme gibi hizmetlerin hassasiyetini artırmaktadır. Ayrıca aktivite tespiti uygulamaları, sağlıklı yaşam konusunda destek olabilmektedir. Yaşlı insanların düşmesi gibi tehlikeli eylemlerin algılanmasını ve bu kötü durumların önlenmesini sağlayabilir. Bu uygulamalar proaktif bir şekilde de yardımcı olabilir. Örneğin, kullanıcıya sağlıklı bir spor alışkanlığı oluşturmak için akıllı telefon kullanıcısı çok uzun süre hareketsiz kaldığı durumlarda bir hatırlatma gönderebilir. Bir başka örnek olarak giyilebilir algılayıcı ve aktivite tanıma tekniklerini kullanan uygulamalar insanların ne kadar yürüdükleri, kaç basamak çıktıkları, ne kadar süre uydukları, kaç kalori yaktıkları gibi bilgileri takip edebilmektedir. İnsan hareketleri ve gerçekleştirilen aktiviteler, algılayıcı verileri ile çeşitli yollarla sınıflandırılabilir ve aktivitelerin karmaşıklık seviyelerine göre sınıflandırmalar gruplandırılabilir. Yürüme, koşma, asansör kullanma gibi aktiviteler basit aktivitelere örnektir. Karmaşık aktiviteler, uzun zaman aralığında gerçekleştirilen aktivitelerin kombinasyonu ile elde edilir (araba sürme, otobüs ile seyahat etme gibi). Aktiviteler vücudun sadece belli bir kısmının hareketine dayanıyor olabilir (yazı yazma, el sallama gibi). Bu konuda rehabilitasyon, egzersiz, düşme tespiti gibi çeşitli sağlık ile ilgili aktiviteler vardır. Yemek yeme, alışveriş

yapma, film izleme gibi eylemler konum tabanlı aktivitelerdir. Bir mekâna girmek veya çıkmak görüntü tabanlı aktivitelerdir. Bu tarz aktivitelerin tespit edilebilmesi için ihtiyaç duyulan algılayıcılar günümüz akıllı telefonlarında dâhili olarak bulunmaktadır. Android ve iOS işletim sisteminin son sürümleri yürüme, sabit durma, koşma ve araç ile seyahat etme durumlarını tahmin edebilen kütüphanelere sahiptir (Su vd., 2014).

### **1.1. Amaç ve Kapsam**

Bu tez çalışmasında, insan aktivitelerinin algılayıcı verileri kullanılarak sınıflandırılması gerçekleştirilmiştir. Aktivite tespiti iki ayrı başlık altında incelenmiştir. Bunlar insan hareketlerinin tespiti ve ulaşım türü tespitidir. Algılayıcı verileri ise akıllı telefon ve akıllı saat olmak üzere iki ayrı cihazdan toplanmıştır. Gerçekleştirilen çalışmalar aşağıda maddeler halinde özetlenmiştir.

- İnsan hareketlerinin (yürüme, bisiklet, durağan, koşma, merdiven inme, merdiven çıkma ve asansör kullanma) akıllı telefon algılayıcıları (GPS, ivmeölçer, jiroskop) ile tespit edilmesi.
- Ulaşım türlerinin (yürüme, koşma, bisiklet sürme, araba veya otobüs ile seyahat etme) akıllı telefon algılayıcıları (GPS, ivmeölçer, jiroskop) ile tespit edilmesi.
- İnsan hareketlerinin (koşma, süpürge kullanma, kâğıda yazı yazma, klavye kullanma, yürüme, tahtaya yazı yazma, hareketsiz durma, diş fırçalama) akıllı saat algılayıcıları (ivmeölçer, jiroskop, kalp hızı, adımsayar) ile tespit edilmesi.

Araç ile seyahat etme durumunda bilek hareketlerinin kendine has hareketleri olmadığından akıllı saat algılayıcı verileri ile sadece insan hareketlerinin tespiti gerçekleştirilmiştir. Bu amaçla akıllı telefonun dâhili ivmeölçer, jiroskop ve GPS algılayıcılarından, akıllı saatin ise ivmeölçer, jiroskop, adımsayar ve kalp hızı algılayıcılarından veriler toplanmıştır. Toplanan algılayıcı verileri ile üç ayrı veri seti

oluşturulmuştur. Verilerin toplanması ve anlık olarak aktivite tespitinin gerçekleştirilebilmesi için akıllı telefonlar ve akıllı saatler üzerinde çalışabilen uygulamalar geliştirilmiştir. Veriler temel makine öğrenmesi yöntemleri (Bayes Ağları, Naive Bayes, Rastgele Orman, C4.5 ve kNN) ve sınıflandırıcı toplulukları (AdaboostM1, Bagging, Rastgele Alt Uzaylar ve Oylama) kullanılarak değerlendirilmiş ve performansları karşılaştırılmıştır. Geliştirilen uygulamada kullanılmak üzere en başarılı algılayıcı kombinasyonu ve sınıflandırma yöntemi gerçekleştirilen testler sonucunda seçilmiştir.

Bu bölümün devamında literatürde yapılan çalışmalara değinilmiştir. İkinci bölümde akıllı cihaz algılayıcıları anlatılmıştır. Üçüncü bölümde sınıflandırma aşamasında kullanılan makine öğrenmesi yöntemleri ve sınıflandırıcı topluluklarından bahsedilmiştir. Dördüncü bölümde geliştirilen sistemler ve mobil uygulamalar anlatılmış ve gerçekleştirilen testler tartışılmıştır. Son olarak beşinci bölümde tez çalışmasından elde edilen sonuçlara değinilmiştir.

## **1.2. Türkiye ve Dünyada Aktivite Sınıflandırma ve Ulaşım Türü Tespiti ile İlgili Yapılan Çalışmalar**

Literatür incelendiğinde algılayıcı verileri kullanılarak gerçekleştirilen insan eylemlerini tanıma ve ulaşım türü sınıflandırması çalışmalarına rastlamak mümkündür. Bu çalışmaların gerek insan vücuduna yerleştirilen algılayıcılarla gerekse akıllı mobil cihazlarla gerçekleştirildiği görülmektedir. Literatürde yer alan benzer çalışmalar aşağıdaki alt başlıklarda açıklanmaktadır.

### **1.2.1. İnsan hareketlerinin akıllı telefon algılayıcıları ile tespit edilmesi ile ilgili literatürde yer alan çalışmalar**

Gyorbíró vd. (2009), akıllı telefon algılayıcıları kullanılarak fiziksel aktivite tanıma işlemi gerçekleştirmiştir. Çalışmada yöntem olarak Yapay Sinir Ağları kullanılmıştır.

Elde edilen sonuçlar altı farklı tipte hareket örüntüsünün yüksek başarı oranında tespit edildiğini göstermiştir.

Kwapisz vd. (2011), tarafından yapılan çalışmada, 29 kişiden yürüme, hafif tempoda koşma, merdiven çıkma ve inme, oturma ve ayakta durma eylemleri gerçekleştirirken, akıllı telefonları ceplerinde konumlanmış durumda ivmeölçer verileri toplanmıştır. Toplanan veriler C4.5, Lojistik Regresyon, Çok Katmanlı Algılayıcı ve Straw Man (Korkuluk) yöntemleri ile test edilmiştir. En iyi sonucu %91,7 ile Çok Katmanlı Algılayıcı vermiştir.

Köse (2012), tarafından yapılan çalışmada, akıllı telefonlar üzerindeki ivmeölçer algılayıcısı kullanılarak insan eylemleri tespit edilmiştir. Çalışmada yürüme, koşma, oturma, ayakta durma, bisiklete binme gibi temel insan hareketleri telefon üzerinden veri işlenmesi ile sınıflandırılmıştır. Bunun yanında Naive Bayes, kümelenmiş kNN ve Karar Ağacı sınıflandırma algoritmalarının çevrimiçi başarımları karşılaştırılmıştır.

Lane vd. (2012), kullanıcılara daha sağlıklı bir yaşam sağlamak için akıllı telefon tabanlı aktivite takibi uygulaması geliştirmiştir. Bu uygulama kullanıcıların fiziksel, sosyal ve zihinsel aktivitelerini gösterebilmektedir. Sınıflandırma yöntemi olarak Naive Bayes Sınıflandırıcı kullanılmıştır.

Köse vd. (2012), akıllı telefonların dâhili ivmeölçer verilerini kullanılarak çevrimiçi eylem tanımada farklı algoritmaların performanslarını incelemiştir. Çalışmada yürüme, koşma, oturma ve ayakta durma eylemlerinin tanınması amaçlanmış ve Naive Bayes ve geliştirilen kümelenmiş kNN algoritması karşılaştırılmıştır.

Doğan (2013), tarafından yapılan çalışmada, kNN algoritması kullanılarak beş temel gündelik eylemin tahmin edilebilmesini sağlayacak öznelik seçimi sunulmuştur. Sistemi enerji verimli kılmak için tüm öznelikler pantolon cebinde taşınan akıllı telefon ivmeölçer verilerden çıkarılmıştır. Elde edilen sonuçlar etkin öznelik seçiminin kNN algoritması ile umut veren doğruluk oranlarına ulaşmanın mümkün olduğunu göstermiştir.

Kansız ve Güvensaz (2013) tarafından yapılan çalışmada akıllı telefon ivmeölçer algılayıcısı verileri ile günlük hayatta meydana gelen kazaları tespit eden ve kazalar sonucunda oluşabilecek durumlara karşı ilgili birimlere haber veren mobil uygulama geliştirilmiştir. Kazaların tespitinde K-Star, Naive Bayes ve J48 yöntemleri kullanılmış ve en başarılı sonuçlar J48 yönteminden elde edilmiştir.

Toplan vd. (2013), kullanıcıların aktivitelerini, ulaşım türlerini, konumlarını ve sosyal etkileşimlerini tespit eden ve olaylara ilişkin sürekli veri toplayan şehir dinamiklerini elde etme amaçlı Android telefonlar üzerinde çalışan bir uygulama geliştirmiştir. Sistem çevrimiçi ve çevrimdışı olarak çalışabilmektedir. Çevrimiçi sistemde toplanan veriler 10 dakika aralıklarla sunucuya aktarılmaktadır. Çevrimdışı sistemde ise toplanan veriler istenilen aralıkta sunucuya gönderilmekte ve çevrimdışı olarak analiz edilmektedir. Yapılan ilk test sonuçlarında çevrimiçi sınıflandırıcı ile eylem tanımada %92 başarı oranı elde edilmiştir.

de la Vega vd. (2013), akıllı telefonların ivmeölçer, jiroskop ve manyetometre algılayıcılarından elde edilen veriler ile insan aktivite tespiti gerçekleştirmiştir. Ayakta durma, yürüme, koşma, tırmanma, merdiven inme, merdiven çıkma ve hafif tempoda koşma eylemlerinin tespiti için Lojistik Regresyon, Naive Bayes, Destek Vektör Makineleri, Bagging-Karar Ağacı ve Sinir Ağları yöntemleri ile testler yapılmıştır.

Alan vd. (2014) yürüme, merdiven çıkma, koşma gibi basit aktivitelerin mobil telefonlardan gözlemlenebilmesi için geliştirilen eylem tanıma uygulamalarının problemlerinden olan eğitim verilerinin toplanması ve etiketlenmesi için Sensor Log uygulaması geliştirmişlerdir. Bu uygulama sayesinde zahmetli ve zaman alan etiketleme süreci kolaylaştırılmıştır.

Coşkun vd. (2014), tarafından yapılan çalışmada akıllı telefonlar üzerinde eylem tanıma işleminde, akıllı telefon taşıma pozisyonlarının (cep, çanta gibi) farklılık göstermesi, eylem tanıma sistemleri için sorun oluşturduğu belirtilmiştir. Çalışmada beş temel insan hareketi ivmeölçer algılayıcısı kullanılarak sınıflandırılmıştır. Bu işlem için 10 farklı kişiden dört farklı pozisyonda (pantolon cebi, sırt çantası, kol çantası ve ceket cebi) beş farklı aktiviteyi (yürüme, oturma, koşma, bisiklete binme

ve ayakta durma) gerçekleştirirken veriler toplanmıştır. Sınıflandırma yöntemi olarak kNN ve Karar Ağacı algoritmaları kullanılmıştır. Deney sonuçlarında kNN algoritmasında %79.2, Karar Ağacı algoritmasında ise %81.7 doğrulukta başarı oranı yakalanmıştır.

Shoab vd. (2014), tarafından yapılan çalışmada, yedi farklı eylemi (yürüme, koşma, ayakta durma, hafif tempoda koşma, oturma, bisiklet sürme, merdiven inme ve çıkma) tespit edebilmek için on katılımcıdan akıllı telefonu farklı pozisyonlarda (sağ cep, sol cep, kol, bel, bilek) taşır vaziyette algılayıcı verileri toplanmıştır. Çalışmada Samsung Galaxy SII marka akıllı cep telefonu kullanılmıştır. Elde edilen algılayıcı verileri Bayes Ağları, Naive Bayes, Destek Vektör Makineleri, Lojistik Regresyon, kNN, C4.5, Rastgele Orman, PART ve NNGE yöntemleri kullanılarak test edilmiştir.

Khan vd. (2014), akıllı telefon tabanlı 15 farklı insan aktivitesini tespit etmiştir. Akıllı telefonun ivmeölçer, mikrofon ve basınç algılayıcılarından veriler toplanmıştır. Bu veriler Yapay Sinir Ağları, Destek Vektör Makineleri ve Gaussian Mixture Model ile test edilip performansları karşılaştırılmıştır.

Sağbaş ve Ballı (2016a) akıllı telefonların GPS, ivmeölçer ve jiroskop algılayıcı verilerini kullanarak insan hareketlerinin (yürüme, koşma, bisiklet sürme, merdiven inme ve çıkma, asansör kullanma, durağan pozisyonda bekleme) tespitinde Lojistik Regresyon ve kNN yöntemlerinin performanslarını karşılaştırmışlardır.

Ronao ve Cho (2016) akıllı telefonlardan elde ettikleri ivmeölçer ve jiroskop verilerini derin öğrenme yöntemi kullanarak insan eylemlerini (yürüme, merdiven inme, merdiven çıkma, ayakta durma, oturma ve uzanma) tespit etmek için kullanmışlardır. Gerçekleştirilen testler sonucunda %90'ın üzerinde doğruluk oranı yakalanmıştır.

Bonnar vd. (Web-1), tarafından yapılan çalışmada oturma, yürüme, koşma, zıplama egzersizi ve ip atlama aktivitelerini tanıyabilen bir Android uygulaması geliştirilmiştir. Uygulama akıllı telefonun ivmeölçer algılayıcısını kullanmaktadır. Elde edilen algılayıcı verileri üç farklı makine öğrenmesi yöntemi ile test edilmiştir.

Bunlar, C4.5 Karar Ağacı, Naive Bayes ve Lojistik Regresyon'dur. Sırası ile %89.37, %86.23 ve %90.57 başarı oranları yakalanmıştır.

### **1.2.2. Ulaşım türü sınıflandırılması ile ilgili literatürde yer alan çalışmalar**

Reddy vd. (2008), akıllı telefonların GPS ve ivmeölçer algılayıcılarından elde edilen veriler ile ulaşım türü sınıflandırması gerçekleştirmiştir. Yöntem olarak Karar Ağacı algoritması kullanılmıştır. 20-28 yaşları arasında gönüllü kişiler üzerinde mobil cihazlar; belinde, göğsünde, elinde, cebinde ve çantasında olacak şekilde deneyler yapılmış. kNN, Naive Bayes, C4.5 Karar Ağacı, Destek Vektör Makineleri, Sürekli Saklı Markov Modeli arasında yapılan karşılaştırmalarda en iyi sonuçlar Karar Ağacı algoritmasından alınmıştır. Mobil cihazı taşıma konumu olarak da en doğru sonuçlar cepte taşımada elde edilmiştir.

Zheng vd. (2008), tarafından yapılan çalışmada altı aylık süre içerisinde 45 kullanıcıdan GPS verileri toplanmıştır. Elde edilen ham GPS verileri ile ulaşım türü tespiti gerçekleştirmek için Karar Ağacı, Bayes Ağları, Destek Vektör Makineleri ve Koşullu Rastgele Alan algoritmaları kullanılarak hesaplamalar yapılmıştır. Yürüme, araba, otobüs, bisiklet ile seyahat etme durumları en iyi Karar Ağacı algoritması ile tahmin edilmiştir.

Wang vd. (2010), akıllı telefonlarda bulunan algılayıcılardan sadece dâhili ivmeölçer algılayıcısını kullanarak ulaşım türü tespiti gerçekleştirmiştir. Altı farklı ulaşım türünün (bisiklet sürme, sabit durma, yürüme ve otobüs, araba, metro ile seyahat etme) tespiti Destek Vektör Makineleri, kNN ve Karar Ağacı algoritmaları ile değerlendirmiştir.

Stenneth vd. (2010), tarafından yapılan çalışmada kullanıcıların cep telefonlarındaki GPS alıcıları yardımı ile ulaşım türü sınıflandırmasından sonuç çıkarmada yeni bir yaklaşım geliştirilmiştir. Çalışmada otobüs yolları ve otobüs durakları ayrıca tanımlanmıştır. Sonuç çıkarmada %93,5 doğruluk oranına ulaşılmıştır. Konu ile ilgili diğer çalışmalarda sadece GPS'e göre %17 GPS ve GIS verilerine göre %9'luk bir oranda artış elde edilmiştir. Öncelikli olarak taşıtların motorlu taşıt mı yoksa



motorsuz taşıt mı olduğu tespiti yapılmıştır. En iyi sonuç Rastgele Orman algoritmasından elde edilmiştir.

Bolbol vd. (2012), ulaşım türlerindeki sınıflandırma sorununa çözüm yolu bulunması amaçlamıştır. Çalışmada, öncelikli olarak fayda sağlayabilecek değişkenler bulmak ve bu değişkenlerin istatistiksel ayırıcı gücünü ölçmek üzerine çalışılmıştır. Daha sonra Destek Vektör Makineleri sınıflandırma dayalı bir çerçeve kullanarak çıkarsama yürütmek için yeni bir yaklaşım tanıtılmıştır. Test işlemleri önceki çalışmalarda kaçınılan iri taneli GPS verileri ile yapılmış. Kappa istatistik yansıtması ile %88 doğrulukta hemen hemen mükemmel denebilecek sonuç elde edilmiştir.

Widhalm vd. (2012) yürüme, bisiklet veya motosiklet kullanma, araba, otobüs, tren, tramvay veya metro ile seyahat etme eylemlerini akıllı telefonların GPS ve ivmeölçer algılayıcılarını kullanarak sınıflandırmıştır. Sınıflandırma yöntemi olarak ise Saklı Markov Modelini benimsemiştir.

Hemminki vd. (2013), tarafından yapılan çalışmada ivmeölçer tabanlı ulaşım türü tespiti gerçekleştirilmiş ve önceki çalışmalarla karşılaştırılmıştır. Sınıflandırma işlemi öncelikle yürüme ve durağan olma şeklinde gerçekleştirilmiş sonrasında otobüs, metro, tren ve tramvay olarak ayrıştırılmıştır. Veriler akıllı telefonlardan sağlanmıştır.

Feng ve Timmermans (2013a), GPS ve ivmeölçer algılayıcılarından elde edilen veriler ile ulaşım türü tanıma işlemi gerçekleştirmiştir. Bunun için sadece GPS verileri, sadece ivmeölçer verileri ve bu iki algılayıcının verilerinin kombinasyonu şeklinde üç çeşit değerlendirme yapılmıştır. Hesaplamalarda Bayes Ağları yöntemi kullanılmıştır. Yürüme, koşma, bisiklet sürme, otobüs, motosiklet, tren, metro, tramvay ve hafif raylı sistem ile seyahat etme eylemlerinde, GPS ve ivmeölçer algılayıcılarının kombinasyonu kullanılarak %91.7 oranında doğru tahminler gerçekleştirilmiştir.

Feng ve Timmermans (2013b), tarafından yapılan çalışmada, GPS verileri ile ulaşım türü tespitinde Bayes Ağları, Naive Bayes, Lojistik Regresyon, Çok Katmanlı Algılayıcı, Karar Tablosu, Destek Vektör Makineleri, C4.5 ve CART

algoritmalarının deęerlendirilmesi yapılmıřtır. Tren, yürüme, bisiklet sürme, otobüs, araba, motosiklet, kořma, tramvay ve metro ulaşım türleri ele alınmıřtır. En iyi sonuç Bayes Ağları ile elde edilmiřtir.

Ellis vd. (2014), tarafından yapılan alıřmada GPS ve ivmeöler algılayıcılarından 150 saatlik veri toplanmıřtır. Toplanan veriler kNN, Naive Bayes, Destek Vektör Makineleri, Karar Ağacı ve Rastgele Orman algoritmaları ile deęerlendirilmiřtir. Bisiklet veya araç ile seyahat etme, yürüme, oturma veya ayakta durma eylemleri %89,9 doęruluk oranı ile Rastgele Orman yöntemi ile tahmin edilmiřtir.

Shin vd. (2014), ulaşım türü tespiti gerçekleřtirmek için bir mobil uygulama geliřtirmiřtir. Geliřtirilen uygulama akıllı telefonun dâhili ivmeölerini ve ağ konumu algılayıcısını kullanmaktadır. Geliřtirilen uygulama ile yürüyor olma ya da araba, otobüs veya tren ile seyahat ediyor olma durumları tespit edilebilmektedir.

Xia vd. (2014), akıllı telefon algılayıcıları kullanılarak ulaşım türü sınıflandırması yapmıřtır. Sınıflandırma işlemini yapılrken öncelikle kullanıcı hareket halinde veya duraęan olup olmadığı durumu tespit edilmiřtir. Motorlu taşıt, bisiklet ile seyahat etme veya yürüyor olma aktiviteleri Destek Vektör Makineleri yöntemi kullanılarak %96.31 oranında doęru sınıflandırılmıřtır.

Saębař ve Ballı (2016b) akıllı telefonların ivmeöler, GPS ve jiroskop algılayıcı verileri ve makine öğrenmesi yöntemleri kullanarak ulaşım türü tespiti gerçekleřtirmiřtir. Bayes Ağları, Naive Bayes, Lojistik Regresyon, kNN, C4.5 ve Rasgele Orman yöntemlerinin başarıları karşılařtırılmıř ve en iyi sonuç Rasgele Orman yönteminden elde edilmiřtir.

### **1.2.3. İnsan hareketlerinin giyilebilir akıllı cihazlar veya insan vücuduna yerleřtirilen algılayıcılar kullanılarak tespit edilmesi ile ilgili literatürde yer alan alıřmalar**

Ravi vd. (2005), yaptığı alıřmada, ivmeöler algılayıcısı kullanılarak kullanıcı etkinliğini sınıflandırmıřtır. alıřmada, ayakta durma, yürüme, kořma, merdiven inme, merdiven ıkma, temizlik yapma, fıralama, oturma olmak üzere sekiz farklı

eylemin sınıflandırılması Karar Tablosu, Karar Ağacı, kNN, Destek Vektör Makineleri ve Naive Bayes algoritmaları kullanılarak gerçekleştirilmiş ve performansları karşılaştırılmıştır.

Parkka vd. (2007), tarafından yapılan çalışmada kalça, el ve ayak bileğine konumlandırılmış ivmeölçer ve jiroskop algılayıcıları ile günlük aktivitelerin tespiti gerçekleştirilmiş ve bu üç konumda elde edilen başarılar karşılaştırmıştır.

Khan vd. (2008), tarafından yapılan çalışmada insan bedenine yerleştirilen üç eksenli ivmeölçer ile dört farklı gündelik eylemin (uzanma, ayakta durma, koşma ve yürüme) Artırılmış Otoregresif Modeli Katsayıları ve Yapay Sinir Ağları yöntemi ile tanınması sağlanmıştır. Yapılan testler sonucu dört aktivitenin tespit edilmesinde %99'un üzerinde doğruluk elde edilmiştir.

Yang vd. (2008), ivme verileri ile Çok katmanlı İleri Beslemeli Sinir Ağları yöntemi kullanılarak aktivite tespiti gerçekleştirmiştir. Yapılan testler sonucunda sistemin yürüme, koşma, ayakta durma, bilgisayarda çalışma, ovma, oturma, temizlik yapma ve diş fırçalama eylemlerinin tahmin edilmesinde %90'ın üzerinde başarı oranına sahip olduğu gösterilmiştir.

Riboni ve Bettini (2011), tarafından yapılan çalışmada, diş fırçalama, yürüyüş yapma, bisiklet sürme, hafif tempoda koşma, ayakta durma, gezinme, merdiven inme, merdiven çıkma ve tahtaya yazı yazma eylemlerini tespit etmek için Android tabanlı akıllı telefon ve SUN marka giyilebilir cihazdan elde edilen algılayıcı verileri kullanılmıştır. Verileri sınıflandırmak için Bayes Ağları, C4.5 Karar Ağacı, Multiclass Lojistik Regresyon, Naive Bayes ve Destek Vektör Makineleri algoritmaları test edilmiş ve en iyi sonuç Multiclass Lojistik Regresyondan elde edilmiştir.

Chernbumroong vd. (2011), insan hareketlerini kullanıcı bileğindeki saatten elde edilen ivmeölçer verilerine göre sınıflandırmıştır. Oturma, ayakta durma, uzanma, yürüme, koşma eylemlerini sınıflandırmak için Yapay Sinir Ağları, Karar Ağaçları olmak üzere 2 farklı yöntem kullanılmış ve başarıları karşılaştırılmıştır.

Wu vd. (2011), 47 katılımcıdan alınan GPS verileri ile aktivite sınıflandırması yapmıştır. Bina içerisinde olma, bina dışında durgun halde bulunma, yürüme ve araç ile seyahat etme durumları değerlendirilmiştir. Yapılan işlemlerde zaman, hız ve konum bilgileri kullanılmıştır. Yöntem olarak ise Rastgele Orman modeli tercih edilmiştir.

Lara vd. (2012), tarafından yapılan çalışmada, kullanıcı göğüs kafesi üzerinde bulunan algılayıcı verileri ile yürüme, koşma, oturma, yukarı çıkma ve aşağı inme eylemlerinin tanınması gerçekleştirilmiştir. Sınıflandırma için Eklemeli Lojistik Regresyon yöntemi kullanılmıştır.

School ve van Laerhoven (2012), kullanıcının bileğine giyebildiği, ivmeölçer algılayıcısına sahip giyilebilir cihazdan elde ettiği algılayıcı verileri ile sigara içme eyleminin tespitini gerçekleştirmiştir. Yöntem olarak Gaussian sınıflandırıcı kullanılmıştır.

Sökün vd. (2012), üç eksenli ivmeölçerden alınan sinyalleri kullanılarak temel fiziksel hareket sınıflandırılması yapılmışlardır. Geliştirilen yöntem ile ivmeölçeri taşıyan insanın araç ile mi, yoksa yaya olarak mı seyahat ettiğinin tespit edilmesi amaçlanmıştır. Alınan veriler belirli zaman aralıklarında incelenmiş ve gerçek zamanlı olarak kNN algoritması kullanılarak sınıflandırılmıştır.

da Silva ve Galeazzo (2013), ez-430 choronos marka saatten elde edilen ivmeölçer algılayıcısı verilerini kullanarak yürüme, koşma, oturma, ayakta durma, uzanma, merdiven inme ve çıkma, bilgisayarda çalışma eylemlerini kapsayan 8 günlük eylemi sınıflandırmışlardır. Çalışmada saniyede 33 örnek ivmeölçer verisi toplanmış ve 128 örnek ile bir desen oluşturulmuştur (3.88 saniye). Sınıflandırma yöntemi olarak Çok Katmanlı Algılayıcı, Destek Vektör Makineleri, k En Yakın Komşu kullanılmıştır.

Ramos-Garcia ve Hoover (2013) yaptıkları çalışmada, bileğe giyilebilen ivmeölçer ve jiroskop algılayıcılarına sahip cihaz ile yemek yeme hareketlerini tanımlamışlardır. Dinlenme, ısırma, içme ve mutfak eşyası kullanmayı içine alan 4 eylem kullanılarak bir Saklı Markov Modeli oluşturulmuş ve performansı k En yakın Komşu Algoritması ile karşılaştırılmıştır.

Dadashi vd. (2013), yüzücülerin koluna ve bacağına yerleřtirdiđi ivmeölçer ve jiroskop algılayıcıları ile kurbađalama yüzme aşamalarının otomatik tespit edilmesini sağlayacak bir Saklı Markov Modeli önermiştir.

Trost vd. (2014), eylem tanımada baskın olmayan sađ kalça ve bilekten elde ettikleri ivme verilerinin başarılarını karşılařtırmıştır. Uzanma, oturma, ayakta durma, yürüme, kořma, dans etme ve basketbol oynama olmak üzere 7 farklı eylemin Lojistik Regresyon yöntemi ile tespiti gerçekleştirilmiştir.

Guiry vd. (2014), akıllı saat ve akıllı telefon gibi akıllı cihazların günlük aktivite tespitindeki rolünü arařtırmıştır. Verilerin eğitilmesi ve 9 farklı günlük aktivitenin tespitinde beř tanınmış makine öğrenmesi yöntemine başvurulmuřtur. Bunlar, C4.5, CART, Naive Bayes, Çok Katmanlı Algılayıcı ve Destek Vektör Makineleridir.

Mortazavi vd. (2014), tarafından Samsung Galaxy Gear akıllı saat ile beř farklı jimnastik hareketinin algılanmasında ivmeölçer algılayıcı ile jiroskop ve ivmeölçer algılayıcısı kombinasyonunun performans farklarının deđerlendirilmesi yapılmıştır. Sınıflandırma yöntemi olarak Rasgele Orman, Karar Ađaçları, Destek Vektör Makineleri ve Naive Bayes yöntemleri karşılařtırılmıştır.

Dong vd. (2014), kullanıcının bileđine yerleřtirdikleri akıllı telefon ile yemek yeme döngülerini tespit etmiştir. Çalışmada, akıllı telefonun ivmeölçer ve jiroskop algılayıcı verileri kullanılmıştır.

Kurban ve Yıldırım (2014), günlük insan aktiviteleri ve düşme hareketinin tespitine yönelik özellik çıkarımı yapılmadan sonuç verebilecek bir sistem tasarımı yapmıştır. Eğitim veri seti 15 erkek 5 bayan olmak üzere 20 kişiden toplanan oturma, kalkma, yürüme, zıplama ve düşme örüntülerini içeren 5'er adet hareket verilerinden oluşmaktadır. Çalışmada Destek Vektör Makineleri, Naive Bayes ve Çok Katmanlı Algılayıcı Ađı olmak üzere üç farklı yöntem kullanılmıştır.

Wang vd. (2015), akıllı saat kullanan bir kullanıcının dizüstü bilgisayar klavyesi kullanım bilgilerini elde etmeyi amaçlamıştır. Tuřa basma el hareketleri ile Bayes çıkarımı yapmak için eğitim aşamasında Samsung Galaxy Live marka akıllı saat

kullanılmıştır. Veriler akıllı saatin ivmeölçer ve jiroskop algılayıcılarından elde edilmiştir.

Shoaib vd. (2015), ivmeölçer ve jiroskop algılayıcıları bulunan akıllı telefon ve akıllı saatlerden elde ettikleri algılayıcı verilerini üç farklı sınıflandırıcı (Destek Vektör Makineleri, k En Yakın Komşu, J48 Karar Ağaçları) ile değerlendirerek 13 farklı eylemi (Sigara içme, yemek yeme, klavye ile yazı yazma, yazı yazma, kahve içme, sohbet etme, yürüme, hafif tempoda koşma, bisiklet sürme, merdiven inme ve çıkma, oturma, ayakta durma) tespit etmişlerdir. Çalışmada akıllı telefon ve bileğe giyilen akıllı saat performansları ayrı ayrı değerlendirilmiştir.

Ballı ve Sağbaş (2016) tarafından yapılan çalışmada, akıllı saatin sadece ivmeölçer algılayıcı verileri ve istatistiksel öğrenme yöntemleri (Naive Bayes, Bayes Ağları, kNN, Lojistik Regresyon ve Çok katmanlı Algılayıcı Ağı) kullanılarak insan eylemleri (klavye ile yazı yazma, temizlik yapma, kağıda yazı yazma, koşma, yürüme, tahtaya yazı yazma, ayakta durma, oturma ve diş fırçalama) sınıflandırılmıştır. En başarılı sonuç Bayes Ağları yönteminden elde edilmiştir.


Sağbaş ve Ballı (2016c) akıllı saat algılayıcı (ivmeölçer ve adımsayar) verileri kullanarak insan hareketlerini tespit etmişlerdir. Yürüme, koşma, ayakta durma, oturma, yazı yazma ve diş fırçalama eylemlerinin tespit edildiği bu çalışmada kNN ve Naive Bayes yöntemlerinin sınıflandırma performansları karşılaştırılmıştır.

## 2. AKILLI CİHAZ ALGILAYICILARI

Bu tez çalışmasında, insan aktivitelerinin tespit edilebilmesi için akıllı telefonların GPS, ivmeölçer ve jiroskop algılayıcılarından, akıllı saatlerin ise ivmeölçer, jiroskop, adımsayar ve kalp hızı algılayıcılarından yararlanılmıştır. Aşağıdaki alt başlıklarda bu algılayıcılar hakkında bilgiler verilmektedir.

### 2.1. GPS Algılayıcısı

GPS, 1970'lerin başlarında Amerika Savunma Bakanlığı tarafından geliştirilen Şekil 2.1.'de gösterilen uydu tabanlı yönlendirme sistemidir. Bu sistem, başta sadece askeri amaçla kullanılmak için geliştirilmiş olsa da ilerleyen zamanda kişisel kullanımı mümkün hale gelmiştir. GPS, dünya üzerinde sınırsız kişiye herhangi bir yerde ve herhangi bir hava şartı altında konum ve zaman bilgisi sağlayabilen pasif bir sistemdir. Yani kullanıcılar uydudan gelen sinyalleri işleyerek konum bilgisine sahip olurlar (El-Rabbany, 2002; Sağbaş ve Ballı, 2016a).



Şekil 2.1. Dünya yörüngesindeki GPS uyduları


Akıllı cihazlarda konum tespiti kablosuz ağlar ve ilişkili buldukları baz istasyonları yardımı ile de yapılabilmektedir. Fakat cihaz GPS algılayıcısına sahip değilse sınırlı bir doğrulukla konum tespiti gerçekleştirilebilmektedir. GPS sinyali aşağıdaki parametreleri içermektedir (Sağbaş ve Ballı, 2015; Web-2).

- **Enlem:** Derece biriminde elde edilir. Enlemin pozitif değerleri ekvatorun kuzeyini, negatif değerleri ekvatorun güneyini belirtir.
- **Boylam:** Ölçümler sıfır meridyenine göredir. Derece biriminde elde edilir. Pozitif değerler doğu meridyenlerini, negatif değerler batı meridyenlerini belirtir.
- **Hız:** Cihazın anlık hızı metre/saniye türünden hesaplanır. GPS sinyali alamadığı takdirde hesaplanamaz. Negatif değerdeki hızlar geçersizdir.
- **Yükseklik (rakım):** Yükseklik metre cinsinden hesaplanır. Pozitif değerler cihazın deniz seviyesinden yüksekliğini belirtir.

Ayrıca GPS'in diğer özellikleri şunlardır (Sağbaş ve Ballı, 2015; Web-3; Web-4):

- El GPS cihazları pasif alıcılardır. Uydulara geri bildirim yapmazlar.
- GPS uyduları atomik saatler kullanılarak senkronize edilmiştir.
- Uydular, belirli aralıklarla geçerli konumları ve zaman bilgilerini içeren sinyaller gönderirler. Bu sinyallerin alıcıya ulaşma zamanına göre alıcı-uydu arasındaki mesafe hesaplanabilmektedir. Şekil 2.2.'de iki boyutta konum bulma örneği gösterilmiştir. Eğer uydu konumları (S1, S2, S3) ve kullanıcı ile uydular arasındaki uzaklıklar ( $\rho_1$ ,  $\rho_2$ ,  $\rho_3$ ) biliniyorsa U ile gösterilen kullanıcı konumu bulunabilir. Eğer iki uzaklık bilgisi kullanılırsa çemberlerin iki kesişim noktası olacağından kullanıcı konumu için iki aday olacaktır. Üçüncü uzaklık bilgisi ile kullanıcı konumu kesin olarak belirlenebilir (Çınar, 2005).
- GPS kapalı ortamlarda çalışmaz.
- GPS, cihazın pil ömrünü çabuk tüketir.
- Bir konum düzeltmesi çok uzun süre alır (30sn-12dk).
- Binalar GPS sinyallerini yansıtır veya tıkar. Bu sebepten dolayı doğruluk oranı yerleşim yerlerinde düşmektedir.






Şekil 2.2. İki boyutta konumlandırma(Çınar, 2005)

## 2.2. İvmeölçer Algılayıcısı

Akıllı telefonların ve akıllı saatlerin dâhili ivmeölçer algılayıcısı Şekil 2.3. ve Şekil 2.4.'de gösterilen eksenler doğrultusunda akıllı telefona ve akıllı saate etki eden ivmeyi ölçer. Ham algılayıcı bilgisi ivmeölçerden üç eksende g cinsinden elde edilir. Ham ivmeölçer algılayıcısı verisinin içeriği 2.1 numaralı denklemde verilmektedir.

$$Acc_i = \langle x_i, y_i, z_i \rangle, i = (1,2,3, \dots) \quad (2.1)$$

İvmelenme değerlerinin yanında ayrıca zaman bilgisi de elde edilir. Mevcut çoğu ivmeölçer, kullanıcı ara yüzünde saniyede kaç örnek veri toplanacağını ayarlamaya imkân sunmaktadır. Bu sayede kullanıcı çalışması için en uygun örnekleme hızını seçebilmektedir (Su vd., 2014).



Şekil 2.3. Akıllı telefon ivmeölçer algılayıcısı eksenleri




Şekil 2.4. Akıllı saat ivmeölçer algılayıcısı eksenleri

İvmeölçer, akıllı cihaz tabanlı eylem tanıma uygulamalarında sıkça kullanılmaktadır. Bu algılayıcının popülerliği konumlandırıldığı cihazın veya taşıyan kullanıcının fiziksel hareketini direkt olarak hesaplayabilmesinden gelmektedir. Örneğin, kullanıcı yürür durumdan zıplar duruma geçerse ivmeölçer sinyallerinin şekli dikey ekseninde değişecektir (Su vd., 2014; Sağbaşı ve Ballı, 2016a). Şekil 2.3. ve 2.4.'e göre X eksenini cihazın yan yüzü üzerinde, Y eksenini dik bir pozisyonda, Z eksenini ise sırtüstü durup durmadığı hakkında bilgi verir (Batmaz vd., 2015). Örneğin; Z değeri 0 veya çok yakın bir değere sahipse cihaz kenarlarının birinin üzerinde duruyor

demektir. İvmeölçer ile işlem yaparken, ivmeölçerin cihazın doğrusal ivmesini hesapladığını, elde edilen sayısal değerın cihaza etki eden yerçekimi kuvveti olduğunu ve eğer cihaz hareket halinde ise cihazın ivmesi ve yerçekimi kuvveti olduğu akılda bulundurulmalıdır (Sağbaşı ve Ballı, 2015).


### 2.3. Jiroskop Algılayıcısı

Jiroskop yön tespiti veya ölçümünde kullanılan bir alettir. Bu alet 1817 yılında Bohnenberger tarafından icat edilmiştir. Gündelik hayatta uçak ve gemilerde yön bulmak için kullanılmaktadır (Sağbaşı ve Ballı, 2015; Web 5).



Şekil 2.5. Dünyanın dönüş hareketi (Ayabakan, 2014)

Şekil 2.5.'de gösterilen dünyanın dönüş hareketi de jiroskopun karakteristik özelliğini taşır. Dünyanın kendi eksenindeki dönüşü dengeleyici etki oluşturur ve kutup yıldızını (Polaris) gösterir şekilde dönmesini sağlar. Hızlı şekilde dönen pervane, küre, top vs. temelde jiroskoptur. Jiroskop yapı olarak Şekil 2.6.'da gösterilen serbest dönüşe sahip rotor (disk) ve birbirine bağlı ve mafsallardan (çemberler) oluşur (Ayabakan, 2014).




Şekil 2.6. Jiroskopun yapısı

Akıllı cihazlarda bulunan jiroskop algılayıcısı akıllı cihazın x, y ve z ekseninde yapmış olduğu açısal hızı vermektedir. Akıllı telefonlar için jiroskop eksen yörüngeleri Şekil 2.7.'de gösterilmektedir. Jiroskop algılayıcısından elde edilen ham veriler akıllı cihazın üç fiziksel eksen etrafında dönüşünü rad/sn (radyan / saniye) cinsinden bildirmektedir. Ham jiroskop algılayıcısı verilerinin içeriği 2.2 numaralı denklemde verilmektedir.

$$Rotasyon_i = \langle x_i, y_i, z_i \rangle, i = (1,2,3, \dots) \quad (2.2)$$

Karakter yönlendirme yapılan akıllı telefon oyunlarında jiroskop algılayıcısından yararlanılmaktadır. Eylem tanıma araştırmalarında bu algılayıcı, yön tespitini gerçekleştirmede yardımcı olarak kullanılmaktadır (Su vd., 2014; Sağbaş ve Ballı, 2016a).



Şekil 2.7. Akıllı telefon jiroskop algılayıcısı eksenleri


#### 2.4. Adımsayar Algılayıcısı

Adımsayar algılayıcısı kullanıcı akıllı cihazını açtığından itibaren atılan adım sayısını vermektedir. Eğer akıllı cihaz kapatılacak olursa adım sayısı sıfırlanır (Web-6). Adımsayar uygulamaları akıllı cihazın dâhili ivmeölçer algılayıcısı ile birlikte çalışmaktadır. Uygulama, verileri hafızasında tutar ve sonrasında ortaya çıkan desenleri inceler. İvmeölçer üç eksenle veri sağlar. Kullanıcı ilk adımını attığında, x eksen değeri kullanıcının harekete başladığı yönde ve oranda artar. Y eksen değeri ise cihazın yüksekliğindeki göreceli değişimi belirtmektedir. Bu eksen değeri kullanıcı adım atarken yükselecek, kullanıcı ayağını yere koyarken ise düşecektir. Bu desenlerin eşleşmesi durumunda adım tespit edilmektedir (Web-7). Adımsayar algılayıcısı bu tez çalışmasında akıllı saat algılayıcıları ile insan hareketlerinin tespit edilmesi aşamasında kullanılmıştır.

## 2.5. Kalp Hızı Algılayıcısı

Kalp hızı algılayıcısı kullanıcının kalbinin dakikada kaç sefer attığı bilgisini geri döndürür. Algılayıcının bildirdiği doğruluk oranı, nabzın okunması sırasındaki durumunu sunar (Web-6). Kalp hızı algılayıcısı bulunan birçok giyilebilir cihaz kalp hızını hesaplamak için PhotoPlethysmography (PPG) denilen yöntemi kullanmaktadır. PPG cilde ışık vererek kan akışı tarafından dağılan ışık miktarını hesaplayan teknik bir terimdir. Bu sayede kalp hızındaki değişim hesaplanabilmektedir. Kalp hızı algılayıcısının yapısı Şekil 2.8.'de gösterilmektedir (Web-8). PPG kalp hızını hesaplamak için dört teknik bileşen kullanmaktadır.

- Optik yayıcı: Genel olarak deri içine ışık dalgalarını göndermek için en az 2 led ışık kaynağından oluşmaktadır. Bunun sebebi cilt tonlarında mevcut bulunan farklılıklardır.
- Dijital sinyal işleyici: Dijital sinyal işleyici kullanıcının cildinden kırılan ışıkları yakalar ve birler ve sıfırlar içerisinde anlamlı kalp hızı verisini hesaplar.
- İvmeölçer: İvmeölçer hareketi ölçer ve hareket toleranslı PPG algoritmalarına girdi olarak dijital sinyal işleyici sinyalleri ile birlikte kullanılır.
- Algoritmalar: Dijital sinyal işleyici ve ivmeölçerden gelen veriler ile yakılan kalori, kalp hızı değişkenliği ve kalp oksijen seviyesi gibi bilgileri hesaplayabilmektedir.



**Şekil 2.8. Optik kalp hızı algılayıcısı yapısı**

Tez çalışmasında kullanılan akıllı saat optik kalp hızı algılayıcısına sahiptir. Akıllı saat algılayıcı verileri ile insan hareketlerini sınıflandırma çalışmasında bu algılayıcıdan faydalanılmıştır.

### 3. SINIFLANDIRMA YÖNTEMLERİ

İnsan aktivitelerinin ve ulaşım türlerinin sınıflandırılmasında çeşitli makine öğrenmesi yöntemleri kullanılmaktadır. Bu tez çalışmasında temel makine öğrenmesi yöntemleri (Naive Bayes, kNN, C4.5, Rastgele Orman ve Bayes Ağları) ve sınıflandırma toplulukları (AdaboostM1, Bagging, Rastgele Alt Uzaylar ve Oylama) kullanılmıştır. Bu yöntemler aşağıdaki alt başlıklarda açıklanmaktadır.

#### 3.1. Makine Öğrenmesi Yöntemleri

Geçmiş çalışmalarda makine öğrenmesi yöntemleri insan aktivitelerinin sınıflandırılmasında başarılı bir şekilde kullanılmıştır. Makine öğrenmesi veri üzerinden eğitim gerçekleştiren ve çıkarımda bulunan bir yapı kurar (Kohavi ve Provost, 1998). Bu bölümde, bu tezde kullanılan makine öğrenmesi yöntemleri anlatılmaktadır.

##### 3.1.1. Naive Bayes

Naive Bayes Sınıflandırıcısı güçlü nitelik bağımsızlığı varsayımına sahip, olasılığa dayalı basit bir algoritmadır. Naive Bayes Sınıflandırıcısı test verisi üzerinden öğrenme işlemini gerçekleştirir ve en yüksek orandaki örneğini sınıfa dâhil eder.  $C$  bir sınıfı gösterdiği düşünölsün.  $x = \langle x_1, x_2, x_3, \dots, x_m \rangle$  değeri ise gözlemlenen niteliklerin değeri olsun.  $c$  bilinen bir sınıf etiketini,  $x = \langle x_1, x_2, x_3, \dots, x_m \rangle$  ise bilinen ve gözlemlenen niteliklerin değeri temsil etsin.  $x$  test verisine göre sınıfı tahmin etmek için Bayes Teoremi olasılık hesaplar.

$$p(C = c_j | X = x) = \frac{p(C = c_j)p(X = x | C = c_j)}{p(X = x)} \quad (3.1)$$



Sonrasında en yüksek olasılık ile sınıfı tahmin eder. Bu örnekte  $X=x$  durumu  $X_1=x_1 \wedge X_2=x_2 \wedge X_3=x_3 \wedge \dots \wedge X_m=x_m$  ifade eder.  $p(X=x)$  sınıflar arasında değişme göstermediği durumda ihmal edilir ve 3.1 numaralı denklem aşağıdaki şekle gelir.

$$p(C = c_j | X = x) = p(C = c_j)p(X = x | C = c_j) \quad (3.2)$$

$(C=c_j)$  ve  $p(X=x | C=c_j)$  öğrenme verilerinden tahmin edilir.  $X_1, X_2, X_3, \dots, X_m$  nitelikleri birbirlerine koşullu olarak bağımsızdırlar. Bu durumda 3.2 numaralı denklem aşağıdaki şekli alır.

$$p(C = c_j | X = x) = p(C = c_j) \prod_{i=1}^m p(X_i = x_i | C = c_j) \quad (3.3)$$

3.3 numaralı Naive Bayes denklemini kullanarak test örneklerini hesaplamak ve öğrenme verilerinden tahminde bulunmak daha kolaydır. Naive Bayes Sınıflandırıcı hem kategorik hem de sayısal özellikleri işleyebilir. Her bir ayrık öznelik için, 3.3 numaralı denklemdeki  $p(C = c_j | X = x)$  0 ile 1 arasındaki gerçek sayılar ile modellenir. Eğitim verilerindeki örnekleri sıklıkları ile tahmin olasılıkları elde edilir. Bu yaklaşımda eğer  $x_i$  eğitim verileri arasında hiç geçmiyorsa  $p(X_i = x_i | C = c_j)$  sonucu sıfır elde edilecektir (Chandra vd, 2007; Sağbaş ve Ballı, 2016b).

### 3.1.2. kNN (k En yakın komşu – k Nearest neighbor)

Sınıflandırma tekniklerinden olan k-en yakın komşu yöntemi mesafeye dayalı olarak sınıflandırma yapan çok bilinen bir algoritmadır. Öznelikleri arasında bağlantı olmayan bu yöntem yorumlaması ve uygulanması basit ve sonuç çıkarması kolay olan denetimli makine öğrenimi algoritmalarındandır. K-en yakın komşuluk yöntemi, n boyutlu öznelik uzayında desenleri sınıflandırmak ya da tahmin etmek için en yakın komşu örneklerini kullanır. K-en yakın komşu algoritmasında sınıflandırma yapılabilmesi için kaç adet en yakın komşu sayısının hesaba katılacağı, k gibi bir pozitif tam sayı ile ifade edilir. k değerinin 1 olduğu durumda ise sınıflandırılmaya çalışılan desen en yakın komşusunun bulunduğu sınıfa dâhil olacaktır. Bu yöntem tahmin için de kullanılmaktadır.

En yakın komşuların belirlenmesinde seçilen örnek ile eğitim kümesindeki örnekler arasındaki mesafe ölçümü yapılır. Örnekler arasındaki mesafeler en azdan en fazlaya doğru sıralanır, bu sıralama aynı zamanda seçilen örneğe en yakın komşudan en uzak komşuya olan sıralamayı da gösterir (Köktürk, 2012). Mesafe hesabı olarak ise yaygın bilinen eşitlik 3.4'te verilen Manhattan uzaklık ölçütü, eşitlik 3.5'te verilen Öklid uzaklık ölçütü ve eşitlik 3.6'da verilen Minkowski uzaklık ölçütü formülleri aşağıdaki gibidir:

$$d(i, j) = |X_{i1} - X_{j1}| + |X_{i2} - X_{j2}| + \dots + |X_{ip} - X_{jp}| \quad (3.4)$$

$$d(i, j) = \sqrt{|X_{i1} - X_{j1}|^2 + |X_{i2} - X_{j2}|^2 + \dots + |X_{ip} - X_{jp}|^2} \quad (3.5)$$

$$d(i, j) = \sqrt[p]{|X_{i1} - X_{j1}|^p + |X_{i2} - X_{j2}|^p + \dots + |X_{ip} - X_{jp}|^p} \quad (3.6)$$

### 3.1.3. C4.5

C4.5 algoritması, kategorik ve sayısal değerlere sahip niteliklerin sınıflandırılma ağaçlarının elde edilmesini sağlamaktadır. Sınıflandırma ağaçları oluşturulurken hangi nitelikten dallanmaya başlanacağı önem arz etmektedir. Bir eğitim veri setinden istifade ederek mümkün olan bütün ağaç yapılarını ortaya çıkarmak ve bu ağaç yapılarının içlerinden en uygun olanını seçmek çok sayıda işlemin tekrarlanmasına sebep olmaktadır. Bu nedenle sınıflandırma ağacı algoritmaları daha işlemin en başında çeşitli değerleri hesaplayarak, bu değerlere göre ağaç oluşturma yoluna gitmektedir. Bu amaçla entropi kavramı kullanılabilir. Ağacın dallanması entropinin alacağı değere göre gerçekleşecektir.

Sınıf niteliğinin alacağı değerlere göre sınıf niteliğinin  $\{C_1, C_2, \dots, C_k\}$  olmak üzere  $k$  sınıfa ayrıldığı varsayılınsın. Sınıf niteliği (T) için  $P_T$  sınıfların olasılık dağılımıdır ve eşitlik 3.7'deki gibi hesaplanmaktadır.

$$P_T = \left( \frac{|C_1|}{|T|}, \frac{|C_2|}{|T|}, \dots, \frac{|C_k|}{|T|} \right) \quad (3.7)$$

$|C_i|$  ifadesi  $C_i$  kümesindeki elemanların sayısını vermektedir. Burada örneğin  $p_1 = \frac{|C_1|}{|T|}$  olasılığını ifade etmektedir. O halde  $P_T = (p_1, p_2, \dots, p_k)$  yazılabilir.  $T$  için ortalama bilgi miktarı entropi cinsinden eşitlik 3.8 kullanılarak ifade edilmektedir. (Özkan ve Selçukcan Erol, 2015).

$$H(T) = H(P_T) = - \sum_{i=1}^k p_i \log_2(p_i) \quad (3.8)$$

### 3.1.4. Rastgele Orman

Tek bir ağaç yapısı yerine, çok sayıda ağaç yapısının kullanılması, yani bir ormanın sınıflandırma amacıyla kullanılabilmesi fikri Breinman (2001) tarafından sunularak yöntemin esasları belirlenmiştir. Algoritması Şekil 3.1.'de verilen Rastgele orman yönteminde, veri kümesinden Bootstrap yöntemi ile örnekler seçilmekte ve bu örneklere dayalı olarak sınıflandırma ağaçları oluşturulmaktadır. Bu sınıflandırma ağaçları kullanılarak her bir ağaç için gözlemin sınıfı kestirilir ve sınıflandırmalar arasında en çok tekrar eden sınıf değeri seçilir. Rasgele orman algoritması kullanılarak gerçekleştirilen sınıflandırmanın işlem adımları aşağıdaki gibidir (Özkan ve Selçukcan Erol, 2015).

- Veri setinden Bootstrap yöntemiyle  $n$  adet  $V_1, V_2, \dots, V_n$  örnek veri kümeleri oluşturulur.
- Oluşturulan bu veri kümelerinin her biri değerlendirilerek  $A_1, A_2, \dots, A_n$  sınıflandırma ağaçları oluşturulur. Sınıflandırma işlemlerinde herhangi bir ağaç yapılı sınıflandırma yöntemi kullanılabilir. Elde edilen ağaçlar üzerinden budama işlemi yapılmaz.
- Şekil 3.1. üzerinde görüldüğü gibi, yeni bir gözlem için her bir ağaç kullanılarak sınıf kestirimi yapılır.
- Rastgele orman yönteminde her bir ağacın oluşturulmasında kullanılan yöntem sonucun belirlenmesi açısından önemlidir. Eğer sınıflandırma ağaçları kullanılıyorsa yeni gözlemin sınıfı, en çok oyu alan sınıf olarak belirlenir. Regresyon ağaçlarının kullanılması durumunda ise elde edilen tahmin değerlerinin ortalaması alınır (Özkan ve Selçukcan Erol, 2015).

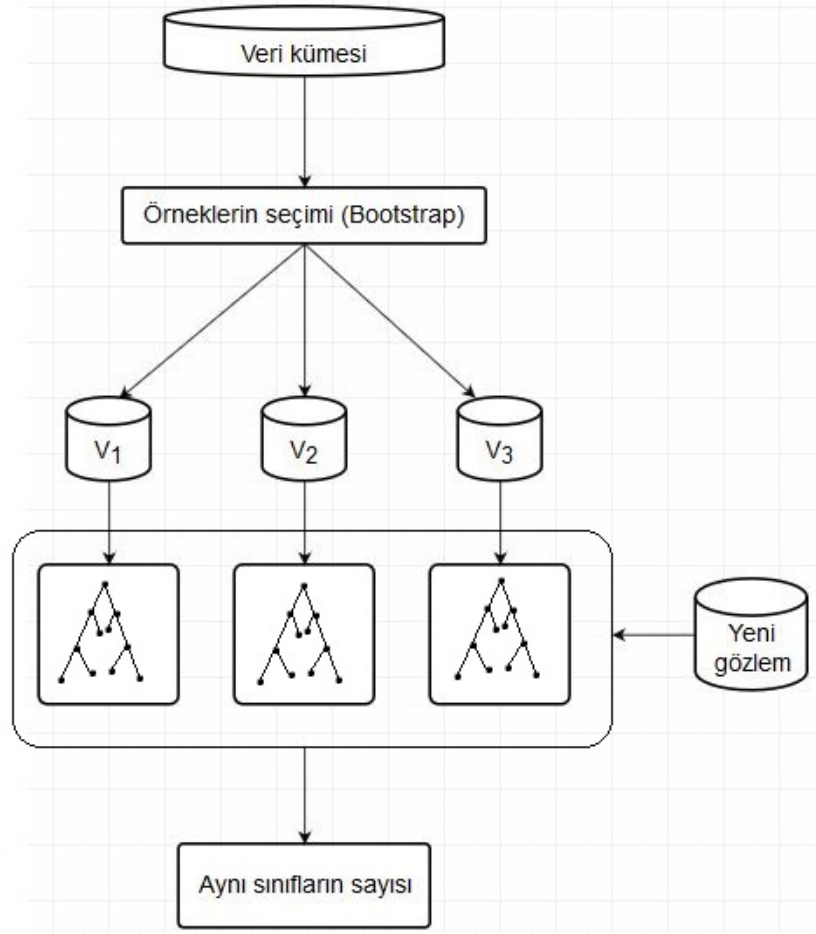
Örneğin seçildiği veri kümesi

Örneğin oluşturulması

Öğrenme veri kümeleri

Sınıflandırma ağaçlarının oluşturulması

Sınıfların oylanması ve en çok tekrarlanan sınıfın seçilmesi



Şekil 3.1. Rasgele orman algoritması (Özkan ve Erol, 2015)

### 3.2. Sınıflandırıcı Toplulukları

Sınıflandırıcı toplulukları, kendi tahminlerinden bir oyalama yaparak yeni bir sınıflandırma yöntemi oluşturan öğrenme algoritmalarıdır (Dietterich, 2000). Bu tez çalışmasının akıllı saat algılayıcı verileri ile insan hareketlerinin tespit edilmesi aşamasında dört farklı sınıflandırıcı topluluğunun performansı karşılaştırılmıştır. Bu yöntemler aşağıdaki alt bölümlerde açıklanmaktadır.

### 3.2.1. AdaBoostM1

AdaBoost (Adaptive Boosting), Freund ve Schapire tarafından 1996 yılında sunulan popüler bir sınıflandırıcı topluluğu algoritmasıdır. Bu algoritma sınıflandırılması zor olan desenlere odaklanmaktadır. Algoritmanın her bir yinelemesinde, hatalı sınıflandırılan örneklerin ağırlıkları artırılır, doğru sınıflandırılan örneklerin ağırlıkları ise azaltılır (Rokach, 2010). AdaBoostM1 algoritması işlem adımları (Kuncheva, 2004) aşağıda verilmiştir.

#### Eğitim Aşaması

1. Parametreler tanımlanır.
  - Ağırlıklar belirlenir.  $w^1 = [w_1, \dots, w_N]$ ,  $w_j^1 \in [0,1]$ ,  $\sum_{j=1}^N w_j^1 = 1$ .
  - Sınıflandırıcı topluluğu  $D = \emptyset$  olarak tanımlanır.
  - $L$ , Eğitim için sınıflandırıcı sayısı.
2.  $k = 1, \dots, L$  için
  - $w^k$  dağılımını kullanarak  $Z$ 'den bir  $S_k$  örneği alınır.
  - Eğitim seti olarak  $S_k$  kullanılarak bir  $D_k$  sınıflandırıcısı inşa edilir.
  - Aşağıda verilen formüle göre  $k$  numaralı adımın ağırlıklı topluluk hatası hesaplanır.
  - $\varepsilon_k = \sum_{j=1}^N w_j^k l_k^j$   
( $l_k^j = 1$  Eğer  $D_k$  sınıflandırılmamış  $z_j$  ve  $l_k^j = 0$  bunun dışında ise)
  - Eğer  $\varepsilon_k = 0$  veya  $\varepsilon_k \geq 0.5$  ise,  $D_k$  ihmal edilir, ağırlıklar tekrar tanımlanır  $w_j^k$  dan  $1/N$ 'e kadar  
 $\varepsilon_k \in (0,0.5)$  ise  $\beta_k = \frac{\varepsilon_k}{1-\varepsilon_k}$
  - Ağırlıklar güncellenir:  $w_j^{k+1} = \frac{w_j^k \beta_k^{(1-l_k^j)}}{\sum_{i=1}^N w_i^k \beta_k^{(1-l_k^i)}}$  ( $j=1, \dots, N$ )
3.  $D$  ve  $\beta_1, \dots, \beta_L$  değerlerini döndür.

#### Sınıflandırma Aşaması

4. Sınıf için destek bilgisi hesaplanır:  $\mu_t = \sum_{D_k(x)=W_t} \ln\left(\frac{1}{\beta_k}\right)$
5. En büyük desteğe sahip sınıf  $x$  için etiket olarak seçilir.

### 3.2.2. Bagging

Bagging (Bootstrap AGGREGatING) terimi Breinman tarafından 1996'da tanıtılmıştır Bagging, basit ve cazip bir fikirdir. Bu fikir, eğitim setinden yeni bir sınıflandırıcı inşa eder. Bu durumda veri setinde bulunan bazı örnekler yeni oluşturulan eğitim

setinde bulunmazken bazıları birden fazla defa bulunur. Sınıflandırıcı topluluğundaki her bir temel sınıflandırıcı farklı örnekler barındıran bu eğitim setleri ile eğitilirler. Sınıflandırıcı çıktıları çoklu oylama ile birleştirilerek sonuca varılır (Kuncheva, 2004; Amasyalı ve Ersoy, 2011). Bagging algoritması (Kuncheva, 2004) işlem adımları aşağıda verilmektedir.

#### Eğitim Aşaması

1. Parametreler tanımlanır
  - $D = \emptyset$ , sınıflandırıcı topluluğu.
  - $L$ , Eğitim için sınıflandırıcı sayısı.
2.  $k = 1, \dots, L$  için
  - Bir Bootstrap örnek ( $S_k$ )  $Z$ 'den alınır..
  - $S_k$  eğitim seti olarak kullanılarak bir sınıflandırıcı  $D_k$  inşa edilir.
  - Yeni sınıflandırıcı mevcut sınıflandırıcı topluluğuna eklenir,  $D = D \cup D_k$ .
3.  $D$ . değerini döndür

#### Sınıflandırma Aşaması

4.  $x$ . girdisi ile  $D_1, \dots, D_L$  sınıflandırıcı topluluklarını oluşturulur.
5. En fazla oyu alan sınıf  $x$  için etiket olarak belirlenir.

### 3.2.3. Rastgele alt uzaylar (RAU)

Rastgele alt uzay verilen öznitelik vektöründen rasgele sayıda eleman seçerek yapı oluşturan bir sınıflandırıcı topluluğudur. Bu algoritmanın amacı, tahmin performansını artırırken rastgele hatayı (overfitting) azaltmaktır. (Ho, 1998; Onan vd., 2016). Rastgele alt uzay algoritmasının (Onan vd., 2016) genel yapısı aşağıda verilmektedir.

**Girdi:**  $S$ : Eğitim seti,  $B$ : Alt uzay sayısı,  $p^*$ : Alt uzay boyutu.

**Çıktı:**  $E$ : Sınıflandırıcı Topluluğu

$E \leftarrow 0$

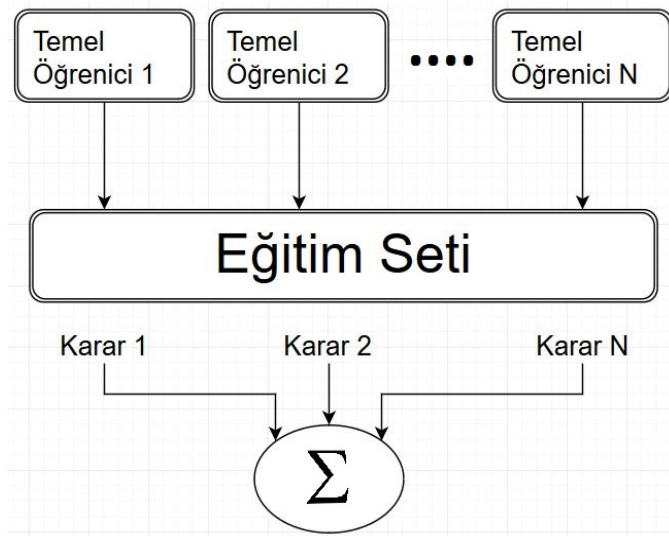
$i = 1, \dots, B$  için

- Eğitim setinden ( $S$ ), ( $p^*$ ) boyutunda rastgele alt uzay seçilir ( $S^i$ ).
- Seçilen rastgele alt uzay ( $S^i$ ).ile  $C^i$  sınıflayıcısı eğitilir.
- $C^i$  sınıflayıcısı  $E$  sınıflandırıcı topluluğuna dâhil edilir.

$E$  değerini döndür.

### 3.2.4. Oylama

Oylama, temel öğrenme algoritmalarının birleştirmenin basit bir yöntemidir. Temel sınıflandırma algoritmalarının çıktılarını birleştirmenin çeşitli yöntemleri bulunmaktadır. Bu birleştirme yöntemleri çoğunluklu oylama ve ağırlık oylamayı içermektedir. Basit çoğunluklu oylamada, k adet temel sınıflandırma algoritması arasından en çok oyu aldığı tespit edilen sonuç sınıflandırıcı topluluğunun çıktısı olarak belirlenir (Onan vd., 2016). Oylama algoritmasının şeması Şekil 3.2.'de gösterilmektedir.



Şekil 3.2. Oylama algoritmasının şeması (Kökçü vd., 2014)

## 4. AKTİVİTE SINIFLANDIRMA ve ULAŞIM TÜRÜ TESPİTİ İÇİN UYGULAMA GELİŞTİRİLMESİ

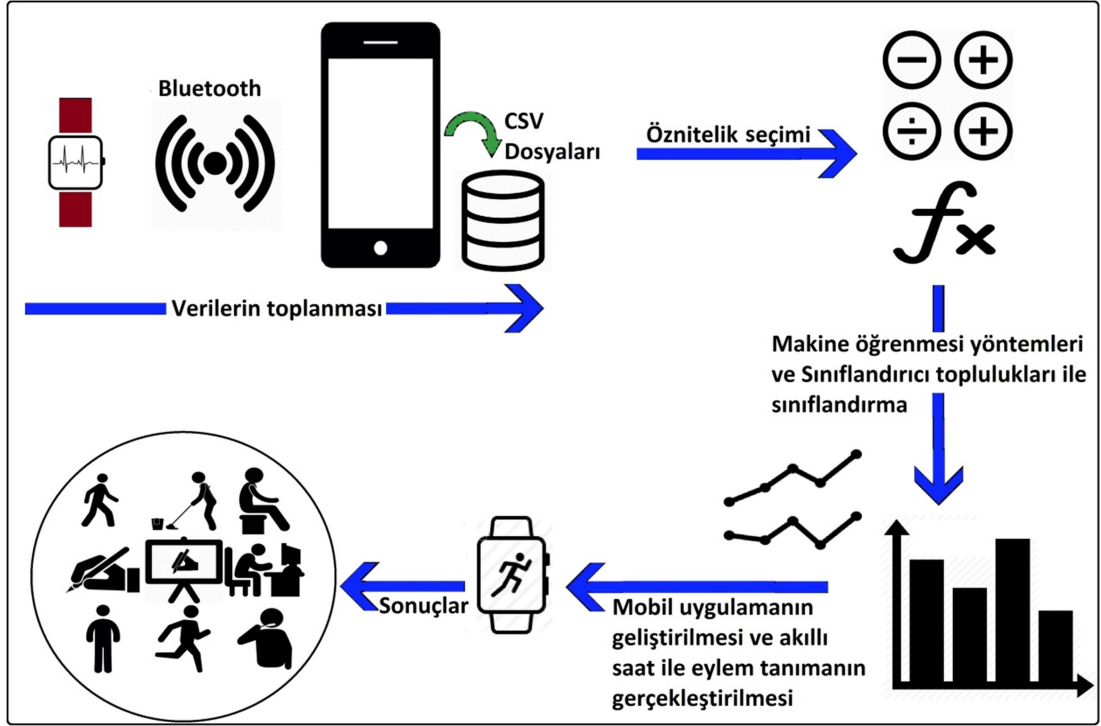
Bu tez çalışmasında, akıllı telefon ve akıllı saat algılayıcıları ve makine öğrenmesi yöntemleri kullanılarak üç farklı aktivite sınıflandırma işlemi gerçekleştirilmiştir. Bu işlemler sırasıyla aşağıdaki gibidir.

- İnsan hareketlerinin akıllı saat algılayıcıları ile tespit edilmesi.
- Ulaşım türlerinin akıllı telefon algılayıcıları ile tespit edilmesi.
- İnsan hareketlerinin akıllı telefon algılayıcıları ile tespit edilmesi.

Her bir işlemde kullanılmak üzere üç ayrı veri seti oluşturulmuştur. Bu veri setlerini oluşturmak için Android tabanlı mobil uygulamalar geliştirilmiştir. Naive Bayes, kNN, C4.5 ve Rastgele Orman yöntemleri temel sınıflandırıcı yöntemleri olarak belirlenmiştir. Sınıflandırıcı topluluğu olarak ise dört yöntemin (AdaboostM1, Bagging, Rastgele alt uzaylar ve Oylama) performansları karşılaştırılmıştır.

Akıllı cihazlar ile insan hareketlerinin ve ulaşım türlerinin sınıflandırılmasının işlem adımları Şekil 4.1.'de gösterilmektedir. Veri setinin elde edilmesi, özniteliklerin seçilmesi, makine öğrenmesi yöntemleri ve sınıflandırıcı toplulukları kullanılarak aktivitenin tespit edilmesi ve mobil uygulama geliştirilmesi her bir çalışma için ayrı ayrı gerçekleştirilmiştir. Bu işlemler alt başlıklarda anlatılmaktadır.





Şekil 4.1. Akıllı cihazlar ile insan hareketlerinin ve ulaşım türlerinin sınıflandırılması için akış şeması

#### 4.1. İnsan Hareketlerinin Akıllı Saat Algılayıcıları ile Tespit Edilmesi

Tez çalışmasının bu aşamasında akıllı saat algılayıcıları (ivmeölçer, jiroskop, adımsayar ve kalp hızı) kullanılarak Şekil 4.2.'de gösterilen insan hareketlerinin (yürüme, koşma, tahtaya yazı yazma, diş fırçalama, kâğıda yazı yazma, temizlik yapma, klavye ile yazı yazma ve hareketsiz durumda olma) tespiti gerçekleştirilmiştir. Hareketsiz durumda olma eylemi, oturma ve ayakta durma eylemlerini içermektedir. Bu amaçla oluşturulan veri seti, öznitelik seçimi, gerçekleştirilen deneyler ve geliştirilen mobil uygulamalar aşağıdaki alt başlıklarda anlatılmaktadır.



Şekil 4.2. Gerçekleştirilen insan hareketleri

#### 4.1.1. Veri seti

İnsan hareketlerinin akıllı saat algılayıcıları ile tespit edilebilmesi için Şekil 4.3.'de görseli verilen Android Wear işletim sistemine sahip ikinci nesil Moto 360 (Sağbaş vd., 2016; Web-9) marka akıllı saat kullanılmıştır. Bu cihaz Quad Core 1.2 GHz işlemci, 512 MB RAM ve dâhili ivmeölçer, jiroskop, ortam ışığı, adımsayar ve kalp hızı algılayıcılarına ve 400mAh bataryaya sahiptir. Algılayıcı verilerini örnekleme hızı olarak SENSOR\_DELAY\_UI ayarlanmıştır. Bu ayar 50 Hz örnekleme hızına izin vermektedir.



Şekil 4.3. Çalışmada kullanılan akıllı saat

Tez çalışmasında kullanılacak veri setini oluşturulması için Android Wear işletim sistemine sahip akıllı saatler üzerinde çalışabilen, algılayıcı verilerini toplayan bir mobil uygulama Java programlama dili kullanılarak geliştirilmiştir. Bu mobil uygulama akıllı telefon ile bağlantılı bir şekilde çalışmaktadır. Akıllı saat uygulamasının Şekil 4.4.'de gösterilen arayüzü algılayıcı verilerini toplamayı başlatacak ya da sonlandıracak bir butona sahiptir.




Şekil 4.4. Akıllı saat için geliştirilen veri seti uygulaması ekran görüntüleri

Toplanan algılayıcı bilgileri bağlı bulunan akıllı telefona aktarılmakta ve telefonun dâhili hafızasına istenilen isim ile CSV formatında kaydedilmektedir. Algılayıcı verilerinin akıllı telefonların dâhili hafızasında depolanmasını gösteren yapı Şekil 4.5.'de gösterilmektedir.



Şekil 4.5. Akıllı saat veri seti uygulaması yapısı

Kişinin gerçekleştirdiği eylemin etiketlenme kısmı akıllı telefon tarafında gerçekleştirilmektedir. Telefon için geliştirilen uygulamanın ekran görüntüsü Şekil 4.6.'de gösterilmektedir.




Şekil 4.6. Veri seti uygulaması akıllı telefon ekran görüntüsü

Akıllı saat için geliştirilen uygulama, saniyede 50 örnek toplayacak şekilde ayarlanmıştır ve saatin eşleşmiş olduğu akıllı telefona aktarılması sağlanmıştır. Çalışmanın bu aşamasında toplamda 400000 ham algılayıcı verisi toplanmıştır. Bu veriler 2 saniyelik (100 veri) pencereye ayrılarak her sınıf için 500 toplamda 4000 (8 sınıf) desen elde edilmiştir. Çalışmada tahtaya yazı yazma, yürüme, koşma, diş fırçalama, kâğıda yazı yazma, klavye kullanma, hareketsiz bulunma ve temizlik yapma eylemleri için veriler toplanmıştır. Yürüme eylemi birey elleri cebinde, eşya taşır durumda ve ellerini sallayarak yürüme olacak şekilde çeşitlendirilmiştir. Bütün eylemlerin verileri toplanırken akıllı saat bireyin, yazı yazarken kullandığı elinin bileğinde konumlandırılmıştır.


#### 4.1.2. Öznitelik seçimi

Akıllı saatten üç ekseninde elde edilen ivmeölçer ve jiroskop algılayıcısı verilerinin ortalamaları ve standart sapma değerleri oluşturulan veri setinde öznitelik olarak seçilmiştir. İvmeölçer algılayıcısı cihazın ne şekilde konumlandırıldığı ve sahip olduğu titreşim hakkında bilgi vermektedir. Jiroskop algılayıcısı ise cihazın açısız

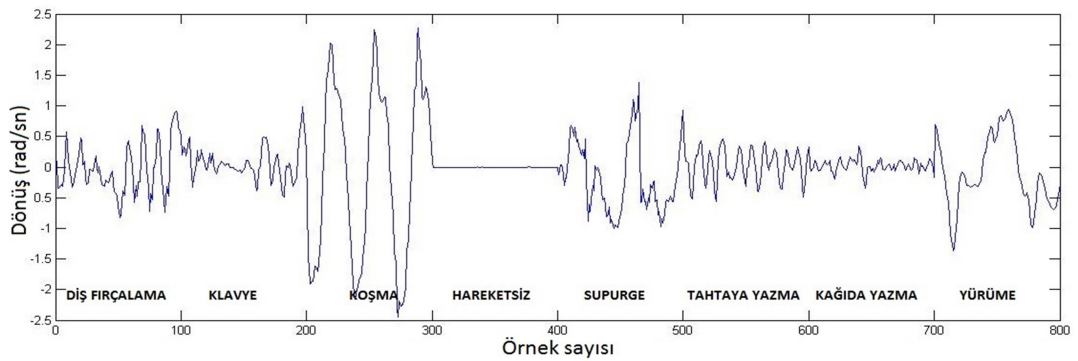
hareketi ölçmektedir. Eylemlere göre örnek ivmeölçer ve jiroskop algılayıcısı verileri Şekil 4.7. ile Şekil 4.10. arasında gösterilmektedir. Jiroskop algılayıcısı verileri yerçekiminden etkilenmediğinden dolayı grafiklerde üç eksenin aynı anda gösterilmesi grafiğin anlaşılabilirliğini azaltmaktadır. Bu sebepten, eylemlere göre jiroskop algılayıcısı örnek verileri her eksen için ayrı ayrı verilmiştir.




Şekil 4.7. Eylemlere göre örnek akıllı saat ivmeölçer algılayıcısı verileri



Şekil 4.8. Eylemlere göre akıllı saat jiroskop algılayıcısının X eksen örnek verileri

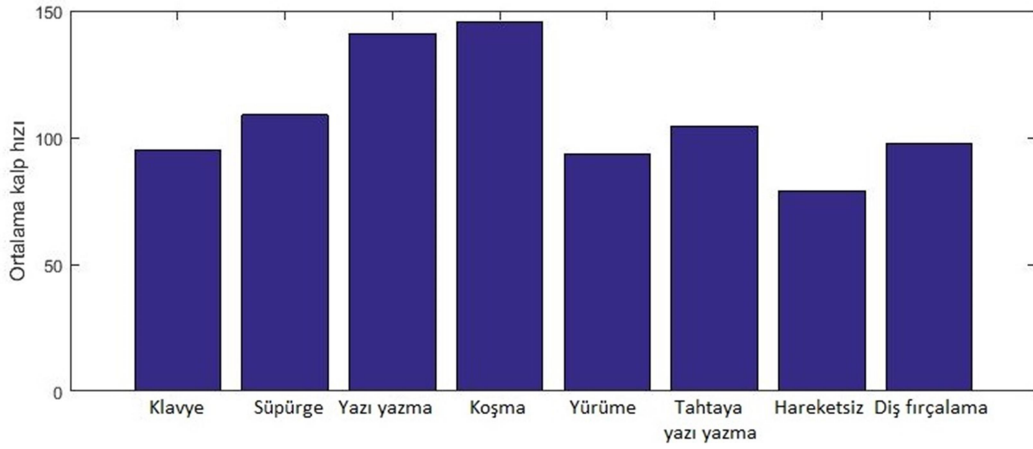


Şekil 4.9. Eylemlere göre akıllı saat jiroskop algılayıcısının Y eksen örnek verileri



**Şekil 4.10. Eylemlere göre akıllı saat jiroskop algılayıcısının Z eksenini örnek verileri**

İvmeölçer ve jiroskop algılayıcısının yanında akıllı saatin sahip olduğu kalp hızı ve adımsayar algılayıcısı verileri de veri setinde öznitelik olarak kullanılmıştır. 2 saniyelik zaman diliminde ortalama kalp hızı ve atılan adım sayısı bu veri setine öznitelik olarak seçilmiştir. Eylemlere göre elde edilen ortalama kalp atış hızları Şekil 4.11.'de, eylemlere göre atılan ortalama adım sayıları ise Şekil 4.12.'de gösterilmektedir.




**Şekil 4.11. Eylemlere göre ortalama kalp atış hızları**

Kalp hızı algılayıcısı nadiren hatalı çalışarak 0 değerini döndürmektedir. Bu hatalı veriler temizlendikten sonra kalp hızı algılayıcısından elde edilen en büyük ve en küçük değerler Çizelge 4.1.'de verilmektedir. Çizelge 4.2. çalışmanın bu aşamasında kullanılan öznitelikleri özetlemektedir.

**Çizelge 4.1. Kalp hızı algılayıcısı veri aralığı**

Eylem	En küçük değer	En büyük değer
Diş fırçalama	46	121
Klavye	65	122
Koşma	78	177
Hareketsiz	73	108
Süpürge kullanma	67	140
Tahtaya yazı yazma	77	162
Kâğıda yazı yazma	94	181
Yürüme	39	124



**Şekil 4.12. Eylemlere göre atılan ortalama adım sayısı**

**Çizelge 4.2. Çalışmada kullanılan algılayıcılar ve öznitelikler**

Kullanılan Algılayıcılar	Öznitelikler
İvmeölçer, Jiroskop, Kalp Hızı, Adımsayar	AccXort, AccYort, AccZort, AccXstd, AccYstd, AccZstd, GyrXort, GyrYort, GyrZort, GyrXstd, GyrYstd, GyrZstd, HR, Step

Çizelge 4.2’de parametreler sütununda gösterilen: AccXstd, ivmeölçerin X ekseninden ölçülen değerlerin standart sapma değerini, AccYstd, ivmeölçerin Y ekseninden ölçülen değerlerin standart sapma değerini, AccZstd, ivmeölçerin Z ekseninden ölçülen değerlerin standart sapma değerini vermektedir. AccXort, ivmeölçerin X ekseninden elde edilen verilerin ortalama değeri, AccYort, ivmeölçerin Y ekseninden elde edilen verilerin ortalama değeri, AccZort, ivmeölçerin Z ekseninden elde edilen verilerin ortalama değeridir. GyrXstd, jiroskop algılayıcısının X ekseninden ölçülen değerlerin standart sapması, GyrYstd, jiroskop algılayıcısının Y ekseninden ölçülen değerlerin standart sapması, GyrZstd, jiroskop algılayıcısının Z ekseninden ölçülen değerlerin standart sapmasıdır. GyrXort, jiroskop algılayıcısının X ekseninde elde edilen verilerin ortalaması, GyrYort, jiroskop algılayıcısının Y ekseninde elde edilen verilerin ortalaması, GyrZort,

jiroskop algılayıcısının Z ekseninde elde edilen verilerin ortalamasıdır. HR, ortalama kalp atış hızını, Step ise atılan adım sayısını sunmaktadır.

#### 4.1.3. Sınıflandırma işlemi ve deneysel bulgular

Akıllı saatin sahip olduğu ivmeölçer, jiroskop, kalp hızı ve adımsayar algılayıcılarından elde edilen veriler makine öğrenmesi ve sınıflandırıcı topluluğu algoritmaları kullanılarak sınıflandırılmıştır. Algılayıcılar arasında performans karşılaştırılması yapılabilmesi için Çizelge 4.3.'de verilen algılayıcı kombinasyonları ayrı ayrı test edilmiştir. Test sonuçları sınıflandırma doğruluk oranları, F-ölçütü (F-measure), eğri altında kalan alan (Area under curve - AUC) ve ortalama karesel hata (Root mean squared error - RMSE) değerleri ile karşılaştırılmıştır.

Çizelge 4.3. Giriş değerlerine göre algılayıcı kombinasyonu model yapısı

Model	İçerik	Değişkenler
1	Sadece ivmeölçer	İvmeölçer algılayıcısı x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri (6 öznitelik)
2	İvmeölçer ve jiroskop	İvmeölçer ve jiroskop algılayıcıları x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri (12 öznitelik)
3	İvmeölçer, jiroskop ve adımsayar	İvmeölçer ve jiroskop algılayıcıları x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri ve atılan adım sayısı (13 öznitelik)
4	İvmeölçer, jiroskop, adımsayar ve kalp hızı	İvmeölçer ve jiroskop algılayıcıları x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri, atılan adım sayısı ve ortalama kalp hızı (14 öznitelik)
5	İvmeölçer ve adımsayar	İvmeölçer algılayıcısı x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri ve atılan adım sayısı (7 öznitelik)
6	İvmeölçer, adımsayar ve kalp hızı	İvmeölçer algılayıcısı x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri, atılan adım sayısı ve ortalama kalp hızı (8 öznitelik)



Deneysel analizler WEKA (Waikato Environment for Knowledge Analysis) Toolkit sürüm 3.8 (Garner, 1995) ve k katmanlı çapraz doğrulama test seçeneđi (Weka varsayılanı olarak k değeri 10 olarak seçilmiştir) kullanılarak gerçekleştirilmiştir.

Çapraz doğrulama seçeneđi test ve eğitim verilerinin limitli olduđu durumlarda kullanılmaktadır. Çapraz doğrulamada veri seti belirlenen k parçaya bölünür. Bölünen parçalardan biri test için, geriye kalan parçalar ise eğitim için kullanılır. Eğitilen model, test için ayrılan kısım ile sınıflandırılır ve doğruluk oranı hesaplanır. Bu işlem k defa tekrarlanır. Modelin doğruluk oranı k defa elde edilen doğruluk oranlarının ortalamasından elde edilir (Witten ve Frank, 2005; Ballı 2016).

Oylama yönteminde Naive Bayes, kNN, C4.5 ve Rastgele Orman temel sınıflandırıcıları ve olasılık kombinasyonlarının ortalaması kuralı seçilmiştir. kNN yönteminde ise k değeri 1 olarak belirlenmiştir. Sınıflandırma yöntemlerinin algılayıcı kombinasyonlarına göre doğruluk oranları Çizelge 4.4.'de verilmektedir. Test sonuçlarına göre elde edilen en iyi sonuç çizelgeler üzerinde kalın yazı tipi ile belirtilmiştir.

**Çizelge 4.4. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre doğruluk oranları**

Algoritmalar/Model	1	2	3	4	5	6
Naive Bayes	96.825	96.550	97.150	97.125	97.375	97.650
AdaBoostM1+NB	96.825	95.975	97.250	97.800	97.375	97.650
Bagging+NB	96.725	96.500	97.200	97.225	97.425	97.675
RAU+NB	96.200	95.725	96.925	96.775	97.150	97.300
kNN	97.925	98.800	98.975	99.050	98.300	98.750
AdaBoostM1+kNN	97.925	98.800	98.975	99.050	98.300	98.750
Bagging+kNN	98.100	<b>98.875</b>	98.975	<b>99.075</b>	98.425	<b>98.775</b>
RAU+kNN	97.625	98.525	98.825	98.975	98.075	98.575
C4.5	97.375	97.750	98.250	98.175	97.775	97.950
AdaBoostM1+C4.5	98.150	98.600	98.900	99,000	98.450	98.725
Bagging+C4.5	97.950	98.300	98.700	98.650	98.175	98.300
RAU+C4.5	97.625	98.025	98.500	98.650	98.275	98.475
Rastgele Orman	98.125	98.700	<b>99,000</b>	99,000	98.525	98.600
AdaBoostM1+RO	<b>98.300</b>	98.725	98.975	99.025	<b>98.550</b>	98.600
Bagging+RO	98.225	98.750	98.875	98.925	98.500	98.500
RAU+RO	96.825	98.450	98.725	98.450	<b>98.550</b>	98.550
Oylama	97.925	98.800	98.925	98.900	98.425	98.700

Altı farklı algılayıcı kombinasyonu test edilmiş ve en yüksek doğruluk oranına sahip sonuç Model 4 algılayıcı kombinasyonu (ivmeölçer, jiroskop, kalp hızı ve adımsayar) ve kNN yönteminin Bagging sınıflandırıcı topluluğuna uygulanması ile elde edilmiştir. Test sonuçları sadece ivmeölçer algılayıcısı verilerinin yüksek doğrulukta başarı sağladığını göstermektedir (En küçük %96.2 doğruluk oranı). Adımsayar ve kalp hızı algılayıcılarının eklenmesi ve sınıflandırıcı topluluklarının kullanılması doğruluk oranının artmasına katkıda bulunmaktadır. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar Çizelge 4.5.'de verilmektedir.

**Çizelge 4.5. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar**

Algoritmalar / Model	1	2	3	4	5	6
Naive Bayes	0.0808	0.0870	0.0819	0.0807	0.0760	0.0724
AdaBoostM1+NB	0.0829	0.0824	0.0704	0.0655	0.0774	0.0724
Bagging+NB	0.0807	0.0868	0.0802	0.0793	0.0750	0.0715
RAU+NB	0.1076	0.1064	0.0903	0.0906	0.0817	0.0905
kNN	0.0719	0.0547	0.0506	0.0487	0.0651	0.0558
AdaBoostM1+kNN	0.0719	0.0547	0.0506	0.0487	0.0651	0.0558
Bagging+kNN	0.0613	0.0497	0.0463	0.0445	0.0564	0.0511
RAU+kNN	0.0818	0.0640	0.0552	0.0558	0.0673	0.0662
C4.5	0.0778	0.0728	0.0639	0.0657	0.0718	0.0691
AdaBoostM1+C4.5	0.0648	0.0569	0.0509	0.0485	0.0608	0.0547
Bagging+C4.5	0.0641	0.0597	0.0535	0.0527	0.0606	0.0583
RAU+C4.5	0.0799	0.0712	0.0617	0.0628	0.0669	0.0663
Rastgele Orman	0.0587	0.0539	0.0488	0.0486	0.0537	0.0519
AdaBoostM1+RO	0.0590	0.0540	0.0487	0.0484	0.0540	0.0522
Bagging+RO	0.0595	0.0551	0.0505	0.0500	0.0553	0.0538
RAU+RO	0.0794	0.0645	0.0608	0.0673	0.0641	0.0644
Oylama	0.0592	0.0514	0.0479	0.0473	0.0550	0.0506

Çizelge 4.5.'e göre en küçük ortalama karesel hata 0.0445 değeri ile Model 4 algılayıcı kombinasyonu ile Bagging+kNN yönteminden elde edilmiştir. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri ve eğri altında kalan ortalama alanlar Çizelge 4.6.' ve Çizelge 4.7.'de verilmektedir.

**Çizelge 4.6. Yöntemlere ve algılayıcı kombinasyonlarına göre ortalama F-ölçütü değerleri**

Algoritmalar / Model	1	2	3	4	5	6
Naive Bayes	0,968	0,966	0,972	0,971	0,974	0,977
AdaBoostM1+NB	0,968	0,960	0,972	0,978	0,974	0,977
Bagging+NB	0,967	0,965	0,972	0,972	0,974	0,977
RAU+NB	0,962	0,957	0,969	0,968	0,971	0,973
kNN	0,979	0,988	0,990	0,991	0,983	0,988
AdaBoostM1+kNN	0,979	0,988	0,990	0,991	0,983	0,988
Bagging+kNN	0,981	0,989	0,990	0,991	0,984	0,988
RAU+kNN	0,976	0,985	0,988	0,990	0,981	0,986
C4.5	0,974	0,978	0,982	0,982	0,978	0,979
AdaBoostM1+C4.5	0,982	0,986	0,989	0,990	0,985	0,987
Bagging+C4.5	0,980	0,983	0,987	0,986	0,982	0,983
RAU+C4.5	0,976	0,980	0,985	0,987	0,983	0,985
Rastgele Orman	0,981	0,987	0,990	0,990	0,985	0,986
AdaBoostM1+RO	0,983	0,987	0,990	0,990	0,985	0,986
Bagging+RO	0,982	0,988	0,989	0,989	0,985	0,985
RAU+RO	0,977	0,985	0,987	0,984	0,985	0,985
Oylama	0,984	0,988	0,989	0,989	0,984	0,987

**Çizelge 4.7. Yöntemlere ve algılayıcı kombinasyonlarına göre eğri altında kalan ortalama alan**

Algoritmalar / Model	1	2	3	4	5	6
Naive Bayes	0,996	0,995	0,995	0,996	0,997	0,997
AdaBoostM1+NB	0,996	0,997	0,998	0,998	0,996	0,997
Bagging+NB	0,997	0,996	0,997	0,997	0,998	0,998
RAU+NB	0,995	0,993	0,995	0,995	0,997	0,998
kNN	0,988	0,993	0,994	0,995	0,990	0,993
AdaBoostM1+kNN	0,988	0,993	0,994	0,995	0,990	0,993
Bagging+kNN	0,995	0,997	0,997	0,997	0,995	0,996
RAU+kNN	0,995	0,998	0,999	0,998	0,996	0,997
C4.5	0,988	0,990	0,992	0,992	0,991	0,992
AdaBoostM1+C4.5	0,998	0,999	1,000	1,000	0,999	0,999
Bagging+C4.5	0,997	0,998	0,999	0,999	0,998	0,998
RAU+C4.5	0,997	0,999	0,999	0,999	0,998	0,999
Rastgele Orman	0,998	0,999	0,999	0,999	0,999	0,999
AdaBoostM1+RO	0,998	0,999	0,999	1,000	0,999	0,999
Bagging+RO	0,999	0,999	1,000	1,000	0,999	1,000
RAU+RO	0,998	0,999	1,000	0,999	0,999	0,999
Oylama	0,999	0,999	0,999	0,999	0,999	0,999

Eğri altında kalan alanlar yöntemlere göre 0.988 ile 1.000 arasında hesaplanmıştır. En büyük F-ölçütü değeri 0.991 değeri ile Model 4 algılayıcı kombinasyonu ve kNN (kNN, Bagging+kNN ve AdaboostM1+kNN) yönteminden elde edilmiştir. En küçük F-ölçütü değeri 0.957 ile Model 2 algılayıcı kombinasyonu ve Rastgele alt uzaylar ile Naive Bayes sınıflandırıcı topluluğundan elde edilmiştir. En yüksek doğruluk oranının elde edildiği Model 4 algılayıcı kombinasyonunun (ivmeölçer, jiroskop, kalp hızı ve adımsayar) sınıflandırma yöntemlerine göre elde edilen karmaşıklık matrisleri Çizelge 4.8. ile Çizelge 4.24. arasında gösterilmektedir.

**Çizelge 4.8. Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	495	0	0	0	4	0	1	0
b=Süpürge	0	484	0	0	14	0	0	2
c=Kağıda yazma	0	1	493	0	6	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	2	0	0	496	2	0	0
f=Tahtaya yazma	0	21	0	0	2	459	1	17
g=Hareketsiz	1	2	0	0	5	5	487	0
h=Diş fırçalama	0	12	0	0	3	14	0	471

**Çizelge 4.9. AdaboostM1+Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	495	0	0	0	2	0	3	0
b=Süpürge	0	489	0	0	6	0	0	5
c=Kağıda yazma	0	0	498	0	2	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	2	0	0	495	2	0	1
f=Tahtaya yazma	0	3	0	0	1	486	4	6
g=Hareketsiz	3	2	5	0	0	1	489	0
h=Diş fırçalama	0	7	0	0	3	29	1	460

**Çizelge 4.10. Bagging+Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	494	0	0	0	5	0	1	0
b=Süpürge	0	485	0	0	13	0	0	2
c=Kağıda yazma	0	2	493	0	5	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	2	0	0	496	2	0	0
f=Tahtaya yazma	0	21	0	0	2	461	0	16
g=Hareketsiz	1	2	0	0	5	5	487	0
h=Diş fırçalama	0	12	0	0	2	13	0	473

**Çizelge 4.11. RAU+Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	495	0	0	0	4	1	0	0
b=Süpürge	0	478	0	0	16	4	0	2
c=Kağıda yazma	0	2	492	0	5	1	0	0
d=Koşma	0	1	0	499	0	0	0	0
e=Yürüme	0	3	0	0	490	6	0	1
f=Tahtaya yazma	0	24	1	0	2	456	1	16
g=Hareketsiz	3	2	0	0	3	3	489	0
h=Diş fırçalama	0	16	0	0	1	14	0	469

Naive Bayes testlerinden elde edilen karmaşıklık matrislerine göre, diş fırçalama eylemi süpürge kullanma eylemiyle, tahtaya yazma eylemi diş fırçalama ve süpürge kullanmayla, süpürge kullanma eylemi ise yürüme eylemi ile karışmaktadır. En başarılı sınıflandırılan eylem koşma olarak görülmektedir.

**Çizelge 4.12. kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	490	0	0	3	3	0	4
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	497	0	1	1
f=Tahtaya yazma	0	1	0	0	0	488	0	11
g=Hareketsiz	1	3	0	0	2	0	494	0
h=Diş fırçalama	1	0	0	0	0	6	0	493

**Çizelge 4.13. AdaboostM1+kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	490	0	0	3	3	0	4
c=Kağıda yazma	0	0	500	0	0	0	0	0
d>Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	497	0	1	1
f=Tahtaya yazma	0	1	0	0	0	488	0	11
g=Hareketsiz	1	3	0	0	2	0	494	0
h=Diş fırçalama	1	0	0	0	0	6	0	493

**Çizelge 4.14. Bagging+kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	490	0	0	3	3	0	4
c=Kağıda yazma	0	0	500	0	0	0	0	0
d>Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	496	1	1	1
f=Tahtaya yazma	0	1	0	0	0	489	0	10
g=Hareketsiz	1	3	0	0	2	0	494	0
h=Diş fırçalama	1	0	0	0	0	5	0	494

**Çizelge 4.15. RAU+kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	492	0	0	2	2	0	4
c=Kağıda yazma	0	0	499	0	0	0	0	1
d>Koşma	0	1	0	499	0	0	0	0
e=Yürüme	0	1	0	0	498	1	0	0
f=Tahtaya yazma	0	2	0	0	1	483	1	13
g=Hareketsiz	3	2	0	0	1	2	492	0
h=Diş fırçalama	0	3	0	0	0	6	0	491

Çizelge 4.12 - 4.15 incelendiğinde klavye ile yazı yazma, kağıda yazı yazma ve koşma eylemlerinin hatasız sınıflandırıldığı görülmektedir. En fazla hatalı



sınıflandırmaya tahtaya yazı yazma eyleminde rastlanmıştır. Bu eylem genel olarak dış fırçalama eylemi ile karışmıştır.

**Çizelge 4.16. C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	497	0	0	0	0	1	2	0
b=Süpürge	0	487	0	0	9	2	0	2
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	2	0	1	491	1	2	3
f=Tahtaya yazma	0	3	1	0	0	476	3	17
g=Hareketsiz	4	1	2	0	1	4	488	0
h=Diş fırçalama	1	5	0	0	0	6	0	488

**Çizelge 4.17. AdaboostM1+C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	499	0	0	0	0	0	1	0
b=Süpürge	0	495	0	0	4	0	0	1
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	0	0	1	496	1	1	1
f=Tahtaya yazma	0	1	0	0	0	488	0	11
g=Hareketsiz	2	2	1	0	0	2	493	0
h=Diş fırçalama	1	4	0	0	0	6	0	489

**Çizelge 4.18. Bagging+C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	488	0	0	8	1	1	2
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	2	0	1	494	2	1	0
f=Tahtaya yazma	0	3	0	0	0	487	0	10
g=Hareketsiz	4	1	3	0	0	4	488	0
h=Diş fırçalama	1	1	0	0	0	9	0	489

**Çizelge 4.19. RAU+C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	499	0	0	0	0	0	1	0
b=Süpürge	0	494	0	0	0	3	0	3
c=Kağıda yazma	0	0	499	0	0	1	0	0
d=Koşma	0	1	0	499	0	0	0	0
e=Yürüme	0	0	0	1	498	1	0	0
f=Tahtaya yazma	0	3	0	0	0	484	0	13
g=Hareketsiz	5	2	0	0	0	5	488	0
h=Diş fırçalama	0	3	0	0	0	8	1	488

C4.5 algoritması ve bu algoritma ile oluşturulan sınıflandırıcı toplulukları ile yapılan testler sonrasında kNN algoritmasından elde edilen karmaşıklık matrislerine benzer sonuçlar elde edilmiştir. En hatalı sınıflandırma tahtaya yazı yazmada görülürken, klavye ile yazı yazma, kâğıda yazı yazma ve koşma eylemleri %100'e yakın başarı ile sınıflandırılmıştır.

**Çizelge 4.20. Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	495	0	0	3	0	0	2
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	498	1	0	0
f=Tahtaya yazma	0	2	0	0	0	488	0	10
g=Hareketsiz	6	1	1	0	0	4	488	0
h=Diş fırçalama	1	1	0	0	0	7	0	491

**Çizelge 4.21. AdaboostM1+Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	499	0	0	0	0	0	1	0
b=Süpürge	0	495	0	0	4	1	0	0
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	498	1	0	0
f=Tahtaya yazma	0	2	0	0	0	487	0	11
g=Hareketsiz	5	1	1	0	1	4	488	0
h=Diş fırçalama	1	1	0	0	0	6	0	492

**Çizelge 4.22. Bagging+Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	496	0	0	3	0	0	1
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	497	2	0	0
f=Tahtaya yazma	0	2	0	0	0	487	0	11
g=Hareketsiz	5	2	2	0	0	3	488	0
h=Diş fırçalama	1	0	0	0	0	9	0	490

**Çizelge 4.23. RAU+Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	497	0	0	3	0	0	0
c=Kağıda yazma	0	1	499	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	499	0	0	0
f=Tahtaya yazma	0	3	0	0	0	479	0	18
g=Hareketsiz	4	2	1	0	0	4	489	0
h=Diş fırçalama	1	4	0	0	0	5	0	490


Çizelge 4.20 – 4.23 incelendiğinde, tahtaya yazı yazma, diş fırçalama ve hareketsiz bulunma eylemlerinde her bir eylemde yaklaşık %2 oranında hatalı sınıflandırmalar gerçekleştiği görülmektedir. Oylama yönteminde ise süpürge kullanma ve tahtaya

yazı yazma eylemlerinin sınıflandırma başarısının bir miktar daha düştüğü gözlemlenmektedir.

**Çizelge 4.24. Oylama yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g	h
a=Klavye	500	0	0	0	0	0	0	0
b=Süpürge	0	492	0	0	6	0	0	2
c=Kağıda yazma	0	0	500	0	0	0	0	0
d=Koşma	0	0	0	500	0	0	0	0
e=Yürüme	0	1	0	0	497	2	0	0
f=Tahtaya yazma	0	2	0	0	0	483	0	15
g=Hareketsiz	3	2	2	0	1	2	490	0
h=Diş fırçalama	1	2	0	0	0	3	0	494

Karmaşıklık matrisleri genel olarak ele alındığında tahtaya yazı yazma eyleminin her yöntemde dış fırçalama eylemi ile karıştığı görülmektedir. Dış fırçalama eylemi ise Naive Bayes ve bu yöntem ile oluşturulan sınıflandırıcı topluluklarında tahtaya yazı yazma ve süpürge kullanma eylemleri ile karışmaktadır. Bu yanlış sınıflandırmalar dış fırçalama eyleminin kendine has karakteristik bir yapısının olmamasından kaynaklanmaktadır. Süpürge kullanma eylemi ise genel olarak yürüme eylemi olarak yanlış sınıflandırılmaktadır. Bunun nedeni ise süpürge eylemi gerçekleştirilirken yürüme eyleminin de gerçekleştiriliyor olmasıdır. Hareketsiz bulunma eylemi ise klavye kullanma, tahtaya ve kâğıda yazı yazma eylemleri ile karıştığı görülmektedir. Bu hatalı sınıflandırmaların nedeni ise bu dört eylemin çok düşük titreşimlere sahip olmasıdır. Eğri altında kalan alanlar her sınıf için hesaplanan değerlerin ortalaması alınarak elde edilmiştir. ROC eğrisi ise sınıflardan elde edilen gerçek pozitiflik oranlarının ortalaması ve yalancı pozitiflik oranlarının ortalaması alınarak çizdirilmiştir. En iyi sonucun elde edildiği Bagging+kNN yöntemine ait ROC eğrisi Şekil 4.13.'de verilmektedir.



**Şekil 4.13. Bagging+kNN yöntemine ait ROC eğrisi**

En yüksek doğruluk oranına sahip olan Bagging sınıflandırıcı topluluğu ile kNN yöntemi ve Model 4 algılayıcı kombinasyonu (ivmeölçer, jiroskop, adımsayar ve kalp hızı) kullanılarak elde edilen eğri altında kalan alan 0.997 olarak hesaplanmıştır. Eğri altında kalan alan en büyük 1 değerini alabilmektedir. Eğri altında kalan alanlar incelendiğinde temel makine öğrenmesi yöntemlerinden ve sınıflandırıcı topluluklarından tatmin edici sonuçlar alındığı görülmektedir. Doğruluk oranları incelendiğinde Bagging+kNN en yüksek doğruluk oranına sahip olmasına rağmen eğri altında kalan alanlarda AdaboostM1+Rastgele Orman ve AdaboostM1+J48 yöntemleri en büyük değerlere sahip oldukları gözlemlenmektedir.

#### **4.1.4. Akıllı saat için eylem tanıma mobil uygulaması geliştirilmesi**

İnsan hareketlerinin çevrimiçi sınıflandırılmasının gerçekleştirilebilmesi için akıllı saatler üzerinde çalışabilen bir mobil uygulama geliştirilmiştir. Bu uygulama aynı saat ile elde edilen veri setini ve 4.1.3. bölümde anlatılan deneyler sonucunda en iyi

sonucu veren yöntemi (Bagging+kNN) kullanmaktadır. Mobil uygulamaya eğitilmiş model yüklenmiştir. Bu sayede uygulama her açılışında ya da her sınıflandırma işlemi gerçekleşmesinde tekrardan eğitim gerekmemekte, böylece sınıflandırma işlemi hızlı bir şekilde gerçekleşebilmektedir. Akıllı saatler için geliştirilen mobil uygulama 2 saniyede bir topladığı algılayıcı verilerini desene çevirmekte, Weka API (Web-11) kullanarak sınıflandırma işlemini gerçekleştirmekte ve tahmin ettiği sınıfı saatin ekranında göstermektedir. Bu uygulama bütün işlemleri bağlı olduğu akıllı telefona ihtiyaç duymadan akıllı saatin kendi bünyesinde gerçekleştirebilmektedir. Böylece bağlı olduğu telefon saat ile haberleşemez durumda olsa dahi işlem yapabilmektedir. Akıllı saat için geliştirilen eylem tanıma uygulamasının ekran görüntüsü Şekil 4.14.'de verilmiştir. Saatin ekran boyutu telefonlara göre daha küçük olması ve kullanılabilirliğinin daha düşük olmasından dolayı saat ekranında sadece son tespit edilen eylem listelenmektedir.



**Şekil 4.14. Akıllı saat için geliştirilen eylem tanıma uygulaması ekran görüntüsü**


Kendi başına sınıflandırma işlemi yapabilen akıllı saat istendiği takdirde akıllı telefon üzerinde çalışan uygulaması ile tahmin edilen eylemleri tarih ve saat bilgileri ile raporlayabilmektedir. Böylece bireyin gerçekleştirdiği eylemler daha detaylı bir şekilde incelenebilmektedir. Telefon üzerinde çalışan ve raporlama yapan uygulamanın ekran görüntüsü Şekil 4.15.'de gösterilmektedir.



Şekil 4.15. Tespit edilen hareketleri akıllı telefonda raporlayan uygulama ekran görüntüsü

#### 4.2. Ulaşım Türlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi

Tez çalışmasının ikinci aşamasında akıllı telefon algılayıcıları (ivmeölçer, jiroskop ve GPS) kullanılarak Şekil 4.16.'de gösterilen ulaşım türlerinin (yürüme, koşma, bisiklet sürme, araba ile seyahat etme ve otobüs ile seyahat etme) tespiti gerçekleştirilmiştir. Bu amaçla oluşturulan veri seti, öznelik seçimi, gerçekleştirilen deneyler ve geliştirilen mobil uygulamalar aşağıdaki alt başlıklarda anlatılmaktadır.



Şekil 4.16. Çalışmada sınıflandırılan ulaşım türleri

#### 4.2.1. Veri seti

Ulaşım türlerinin akıllı telefon algılayıcıları ile tespit edilebilmesi amacı ile veri seti oluşturmak için Şekil 4.17.'de görseli verilen akıllı telefonda algılayıcı verileri toplanmıştır. Çalışmada akıllı telefon olarak Samsung Galaxy Note 2 (GT-N7100) (Web-10) kullanılmıştır. Bu cihaz Quad Core 1.6 GHz işlemci, 2 GB RAM ve dâhili ivmeölçer, GPS, jiroskop, barometre, ortam ışığı, yakınlık algılayıcılarına sahiptir. Saniyede en fazla 100 örnekleme algılayıcı bilgisi sağlayabilmektedir. Algılayıcı verilerini örnekleme hızı olarak SENSOR\_DELAY\_UI ayarlanmıştır. Bu ayar 50 Hz örnekleme hızına izin vermektedir.




Şekil 4.17. Çalışmada kullanılan akıllı telefon

GPS verileri ile hız bilgisi, ivmeölçer ve jiroskop algılayıcısı verileri toplanmıştır. Bütün akıllı telefon verileri, telefon kullanıcının pantolon ön cebinde konumlandırılmış bir pozisyonda toplanmıştır. Ekran görüntüsü 4.18.'de verilen veri seti uygulaması kullanıcının istediği etiket ile verileri telefonun dâhili depolama birimine CSV formatında kaydetmektedir. Kullanıcı gerçekleştireceği aktiviteyi



yazdıktan sonra “Başla” butonuna basarak veri toplamaya başlayabilmektedir. Telefonun butona basma işleminden pantolon cebine konması arasında hatalı verilerin oluşmaması için veri toplama işlemi iki saniye gecikme ile başlamaktadır.



Şekil 4.18. Akıllı telefon için geliştirilen veri seti uygulaması ekran görüntüsü

Ulaşım türü tespiti için 1500000 ham algılayıcı verisi toplanmıştır. Toplanan veriler 12 saniyelik (600 veri) pencerelere ayrılarak her sınıf için 500 toplamda 2500 (5 sınıf) desen elde edilmiştir. Çalışmada yürüme, koşma, bisiklet sürme ve araba veya otobüs ile seyahat etme ulaşım türleri için veriler toplanmıştır. Araba ya da otobüs ile seyahat etme ulaşım türlerine ait veriler yolcu koltuğunda ve araç hareket halinde iken (hız bilgisi 0'dan büyük olduğu durumlar) toplanmıştır. Araba ile seyahat etme verileri 5 farklı araçtan elde edilmiştir.

#### 4.2.2. Öznitelik seçimi

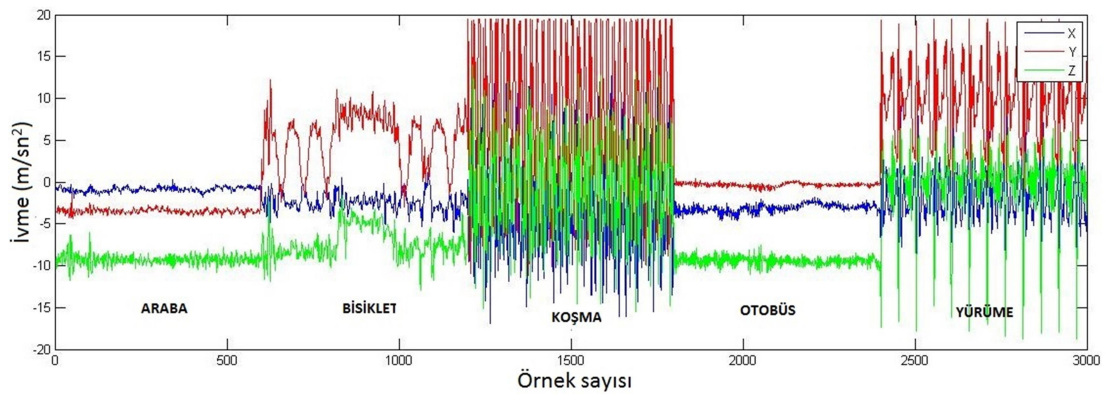
Akıllı telefon ile gerçekleştirilen çalışmanın bu aşamasında GPS, ivmeölçer ve jiroskop algılayıcılarından faydalanılmıştır. İvmeölçer ve jiroskoptan üç ekseninde elde edilen verilerin, akıllı saat ile gerçekleştirilen çalışmada olduğu gibi standart sapma

ve ortalama deęerleri znitelik olarak seilmiřtir. GPS verilerinden ise hız bilgisi kullanılmıř ve ortalama hız ve ulařılan en byk hız deęerleri znitelik olarak seilmiřtir. izelge 4.25. ulařım tr tespitinde kullanılan znitelikleri zetlemektedir. Ulařım trlerine gre rnek ivmeler ve jiroskop algılayıcısı verileri Őekil 4.19. ile Őekil 4.22. arasında gsterilmektedir.

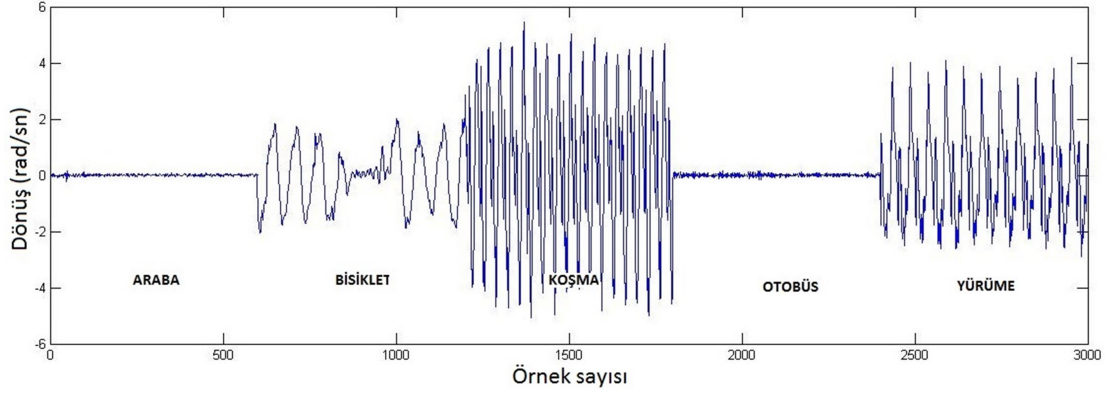
**izelge 4.25. Ulařım tr tespiti alıřmasında kullanılan algılayıcılar ve znitelikler**

Kullanılan Algılayıcılar	Parametreler
GPS, İvmeler, Jiroskop	OrtHiz, MaxHiz, AccXort, AccYort, AccZort, StdXort, StdYort, StdZort, GyrXort, GyrYort, GyrZort, GyrXstd, GyrYstd, GyrZstd


izelge 4.25.'de parametreler stununda gsterilen: MaxHiz, ulařılan en yksek hızı m/sn cinsinden, OrtHiz, ortalama hızı m/sn cinsinden gstermektedir; AccXstd, ivmelerin X ekseninden llen deęerlerin standart sapma deęerini, AccYstd, ivmelerin Y ekseninden llen deęerlerin standart sapma deęerini, AccZstd, ivmelerin Z ekseninden llen deęerlerin standart sapma deęerini vermektedir. AccXort, ivmelerin X ekseninden elde edilen verilerin ortalama deęeri, AccYort, ivmelerin Y ekseninden elde edilen verilerin ortalama deęeri, AccZort, ivmelerin Z ekseninden elde edilen verilerin ortalama deęeridir. GyrXstd, jiroskop algılayıcısının X ekseninden llen deęerlerin standart sapması, GyrYstd, jiroskop algılayıcısının Y ekseninden llen deęerlerin standart sapması, GyrZstd, jiroskop algılayıcısının Z ekseninden llen deęerlerin standart sapmasıdır. GyrXort, jiroskop algılayıcısının X ekseninde elde edilen verilerin ortalaması, GyrYort, jiroskop algılayıcısının Y ekseninde elde edilen verilerin ortalaması, GyrZort, jiroskop algılayıcısının Z ekseninde elde edilen verilerin ortalamasıdır.




**Őekil 4.19. Ulařım trlerine gre rnek akıllı telefon ivmeler algılayıcısı verileri**



**Şekil 4.20. Ulaşım türlerine göre akıllı telefon jiroskop algılayıcısının X eksen örnek verileri**



**Şekil 4.21. Ulaşım türlerine göre akıllı telefon jiroskop algılayıcısının Y eksen örnek verileri**



**Şekil 4.22. Ulaşım türlerine göre akıllı telefon jiroskop algılayıcısının Z eksen örnek verileri**

### 4.2.3. Sınıflandırma işlemi ve deneysel bulgular

Bu bölümde, akıllı telefonda elde edilen ivmeölçer, jiroskop ve GPS algılayıcıları verileri makine öğrenmesi ve sınıflandırıcı topluluğu algoritmaları kullanılarak ulaşım türü (araba, otobüs, bisiklet, koşma, yürüme) sınıflandırılması gerçekleştirilmiştir. Algılayıcılar arasında performans karşılaştırılması yapılabilmesi için Çizelge 4.26.'da verilen algılayıcı kombinasyonları ayrı ayrı test edilmiştir. Deneysel analizler k katmanlı çapraz doğrulama test seçeneği (Weka varsayılanı olarak k değeri 10 olarak seçilmiştir) kullanılarak gerçekleştirilmiştir

**Çizelge 4.26. Giriş değerlerine göre algılayıcı kombinasyonu model yapısı**

Model	İçerikler	Değişkenler
1	Sadece GPS	Ortalama hız ve ulaşılan en büyük hız (2 öznitelik)
2	Sadece İvmeölçer	İvmeölçer algılayıcısı x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri (6 öznitelik)
3	Sadece Jiroskop	Jiroskop algılayıcısı x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri (6 öznitelik)
4	GPS ve İvmeölçer	İvmeölçer algılayıcısı x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri, ulaşılan en büyük hız ve ortalama hız (8 öznitelik)
5	İvmeölçer ve Jiroskop	İvmeölçer ve jiroskop algılayıcılarının x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri (12 öznitelik)
6	GPS, İvmeölçer ve Jiroskop	İvmeölçer ve jiroskop algılayıcılarının x, y ve z eksenlerinden elde edilen değerlerin standart sapma ve ortalama değerleri, ulaşılan en büyük hız ve ortalama hız (14 öznitelik)

Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre sınıflandırma doğruluk oranları Çizelge 4.27.'de verilmektedir. Test sonuçlarına göre elde edilen en yüksek değer çizelge üzerinde kalın yazı tipi ile belirtilmiştir.

**Çizelge 4.27. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre doğruluk oranları**

Algoritmalar/Model	1	2	3	4	5	6
Naive Bayes	79.8	97.52	75.44	97.08	96.72	96.48
AdaBoostM1+NB	79.8	97.6	77.32	97.52	97.04	97.44
Bagging+NB	79.92	97.52	75.8	97	96.76	96.44
RAU+NB	79.72	96.12	75.08	94.64	95.76	95.6
kNN	77.76	98.84	85.24	98.96	99.16	98.96
AdaBoostM1+kNN	77.76	98.8	85.24	98.96	99.16	98.96
Bagging+kNN	78.32	98.8	84.76	98.96	<b>99.2</b>	98.96
RAU+kNN	73.08	98.04	84.36	98.44	98.92	<b>99.12</b>
C4.5	81.48	98.24	86.96	98.4	98.56	98.48
AdaBoostM1+C4.5	80.92	98.76	88.88	98.72	98.72	99
Bagging+C4.5	<b>82</b>	98.56	89.48	98.56	98.56	98.56
RAU+C4.5	81.44	98.56	84.6	98.28	98.4	98.96
Rastgele Orman	80.44	98.8	<b>90.84</b>	<b>99</b>	98.68	98.88
AdaBoostM1+RO	80.24	98.84	90.8	98.84	98.76	99.04
Bagging+RO	80.4	98.76	90.52	98.92	98.84	99
RAU+RO	77.92	98.52	87.6	98.8	98.76	<b>99.12</b>
Oylama	80.64	<b>98.96</b>	88.2	98.84	99.04	98.96

Altı farklı algılayıcı kombinasyonu test edilmiş ve en yüksek doğruluk oranına sahip sonuç Model 5 algılayıcı kombinasyonu (GPS, ivmeölçer ve jiroskop) ve kNN yönteminin Bagging sınıflandırıcı topluluğuna uygulanması ile elde edilmiştir. Gerçekleştirilen testler sonucunda sadece ivmeölçer algılayıcısının yüksek doğrulukta (en küçük %96.12) sınıflandırma yaptığı görülmektedir. Sadece GPS algılayıcısı en yüksek %82 doğruluk oranı ile en başarısız algılayıcı olmuştur. Yalnızca jiroskop algılayıcısı ise GPS'e göre daha başarılı olsa da en büyük %90.84 doğruluk oranı ile ivmeölçerden aşağıda kalmıştır. Fakat jiroskop ve GPS algılayıcılarının ivmeölçer algılayıcısı ile yaptığı kombinasyonlarda doğruluk oranlarının arttığı görülmektedir. Sadece ivmeölçer oylama yöntemi ile en başarılı sonuca ulaşırken, ivmeölçer ve GPS Rastgele Orman (%99), ivmeölçer ve jiroskop ise Bagging+kNN sınıflandırıcı topluluğu (%99.2) ile en başarılı sonucu elde etmişlerdir. Üç algılayıcının birleşimi sonucunda ise %99.12 ile ivmeölçer ve jiroskop algılayıcıları kombinasyonundan elde edilenden bir miktar daha başarısız

sonuç elde edilmiştir. Çizelge 4.27 incelendiğinde Naive Bayes yönteminin ve Naive Bayes ile gerçekleştirilen sınıflandırıcı topluluklarının hiçbir algılayıcı grubunda en yüksek başarıyı gösteremediği gözlemlenmiştir. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar Çizelge 4.28.'de verilmektedir.

**Çizelge 4.28. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar**

<b>Algoritmalar/Model</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
Naive Bayes	0.2407	0.0906	0.2833	0.0952	0.1072	0.1104
AdaBoostM1+NB	0.2606	0.0915	0.2532	0.0929	0.0951	0.0872
Bagging+NB	0.2404	0.0884	0.277	0.093	0.1008	0.1053
RAU+NB	0.2383	0.1358	0.264	0.1262	0.1214	0.1234
kNN	0.2979	0.0683	0.2427	0.0644	0.0579	0.0644
AdaBoostM1+kNN	0.2982	0.0684	0.2429	0.0645	0.0579	0.0645
Bagging+kNN	0.2604	0.0605	0.2138	0.0588	0.0491	0.0584
RAU+kNN	0.2807	0.0851	0.2124	0.0774	0.0632	0.0628
C4.5	0.2347	0.0814	0.2048	0.0791	0.0736	0.0759
AdaBoostM1+C4.5	0.2303	0.0667	0.2009	0.0687	0.0695	0.0627
Bagging+C4.5	0.2217	0.0674	0.1774	0.0683	0.0654	0.0655
RAU+C4.5	0.2316	0.0868	0.2152	0.0833	0.0722	0.0662
Rastgele Orman	0.2355	0.061	0.1671	0.059	0.0583	0.0569
AdaBoostM1+RO	0.2706	0.0655	0.1832	0.0659	0.066	0.0591
Bagging+RO	0.2308	0.0625	0.1708	0.0614	0.0601	0.0593
RAU+RO	0.2482	0.0859	0.1964	0.0732	0.0745	0.0717
Oylama	0.2274	0.0596	0.1839	0.0578	0.057	0.0591

Çizelge 4.28.'e göre en küçük ortalama karesel hata 0.0491 değeri ile Model 5 algılayıcı kombinasyonu ile Bagging+kNN yönteminden elde edilmiştir. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri ve eğri altında kalan ortalama alanlar Çizelge 4.29. ve Çizelge 4.30.'da verilmektedir.

**Çizelge 4.29. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri**

<b>Algoritmalar/Model</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
Naive Bayes	0,791	0,975	0,728	0,971	0,967	0,965
AdaBoostM1+NB	0,791	0,976	0,757	0,975	0,970	0,974
Bagging+NB	0,793	0,975	0,734	0,970	0,967	0,964
RAU+NB	0,789	0,961	0,724	0,946	0,957	0,956
kNN	0,778	0,988	0,852	0,990	0,992	0,990
AdaBoostM1+kNN	0,778	0,988	0,852	0,990	0,992	0,990
Bagging+kNN	0,783	0,988	0,848	0,990	0,992	0,990
RAU+kNN	0,731	0,980	0,843	0,984	0,989	0,991
C4.5	0,809	0,982	0,870	0,984	0,986	0,985
AdaBoostM1+C4.5	0,808	0,988	0,889	0,987	0,987	0,990
Bagging+C4.5	0,817	0,986	0,895	0,986	0,986	0,986
RAU+C4.5	0,809	0,986	0,846	0,983	0,984	0,990
Rastgele Orman	0,804	0,988	0,908	0,990	0,987	0,989
AdaBoostM1+RO	0,802	0,988	0,908	0,988	0,988	0,990
Bagging+RO	0,803	0,988	0,905	0,989	0,988	0,990
RAU+RO	0,778	0,985	0,876	0,988	0,988	0,991
Oylama	0,806	0,990	0,881	0,988	0,990	0,990

**Çizelge 4.30. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre eğri altında kalan ortalama alanlar**

<b>Algoritmalar/Model</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
Naive Bayes	0,963	0,997	0,957	0,997	0,995	0,996
AdaBoostM1+NB	0,921	0,997	0,940	0,997	0,997	0,974
Bagging+NB	0,964	0,998	0,956	0,998	0,997	0,997
RAU+NB	0,964	0,997	0,955	0,996	0,996	0,996
kNN	0,863	0,993	0,908	0,994	0,995	0,994
AdaBoostM1+kNN	0,861	0,993	0,904	0,994	0,995	0,994
Bagging+kNN	0,927	0,999	0,957	0,998	0,999	0,998
RAU+kNN	0,921	0,998	0,974	0,999	0,999	0,999
C4.5	0,950	0,991	0,965	0,992	0,993	0,992
AdaBoostM1+C4.5	0,958	0,998	0,981	0,998	0,998	0,998
Bagging+C4.5	0,964	0,999	0,986	0,999	0,998	0,998
RAU+C4.5	0,957	0,999	0,976	0,999	0,999	0,999
Rastgele Orman	0,961	0,999	0,990	0,999	1,000	0,998
AdaBoostM1+RO	0,942	0,997	0,982	0,999	0,998	0,999
Bagging+RO	0,964	0,999	0,989	0,999	1,000	1,000
RAU+RO	0,955	0,999	0,984	1,000	1,000	1,000
Oylama	0,965	0,999	0,987	0,999	0,999	0,999

Eğri altında kalan alanlar yöntemlere göre 0.861 ile 1.000 arasında hesaplanmıştır. En büyük F-ölçütü değeri 0.992 değeri ile Model 5 algılayıcı kombinasyonu ve kNN (kNN, Bagging+kNN ve AdaboostM1+kNN) yönteminden elde edilmiştir. En küçük F-ölçütü değeri 0.731 ile Model 1 algılayıcı kombinasyonu (Sadece GPS) ve Rastgele alt uzaylar ile kNN sınıflandırıcı topluluğundan elde edilmiştir. En yüksek doğruluk oranının elde edildiği Model 5 algılayıcı kombinasyonunun (ivmeölçer ve jiroskop) sınıflandırma yöntemlerine göre elde edilen karmaşıklık matrisleri Çizelge 4.31 ile Çizelge 4.47 arasında gösterilmektedir.



**Çizelge 4.31. Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	446	47	7	0	0
b=Otobüs	18	478	4	0	0
c=Bisiklet	0	0	499	1	0
d=Koşma	0	0	1	498	1
e=Yürüme	0	0	1	2	497

**Çizelge 4.32. AdaboostM1+Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	448	46	6	0	0
b=Otobüs	15	482	3	0	0
c=Bisiklet	0	0	499	1	0
d=Koşma	0	0	1	498	1
e=Yürüme	0	0	1	0	499

**Çizelge 4.33. Bagging+Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	448	46	6	0	0
b=Otobüs	18	477	5	0	0
c=Bisiklet	0	0	499	1	0
d=Koşma	0	0	1	498	1
e=Yürüme	0	0	1	2	497

**Çizelge 4.34. Rastgele Alt Uzaylar+Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	430	66	4	0	0
b=Otobüs	23	473	4	0	0
c=Bisiklet	0	0	498	1	1
d=Koşma	0	0	1	498	1
e=Yürüme	0	0	1	4	495

Naive Bayes ve bu yöntem ile oluşturulan sınıflandırıcı topluluğu test sonuçları benzer sonuçlar vermiştir. Bisiklet sürme, koşma ve yürüme ulaşım türleri %100'e yakın doğrulukta sınıflandırılmıştır. Araba ve otobüs ile seyahat etme ulaşım türleri

ise %7 ile %10 arasında kendi aralarında ve bisiklet sürme ile hatalı sınıflandırılmıştır.

**Çizelge 4.35. kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	487	11	2	0	0
b=Otobüs	4	495	1	0	0
c=Bisiklet	0	0	499	1	0
d>Koşma	0	0	1	498	1
e=Yürüme	0	0	0	0	500

**Çizelge 4.36. AdaboostM1+kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	487	11	2	0	0
b=Otobüs	4	495	1	0	0
c=Bisiklet	0	0	499	1	0
d>Koşma	0	0	1	498	1
e=Yürüme	0	0	0	0	500

**Çizelge 4.37. Bagging+kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	488	10	2	0	0
b=Otobüs	5	494	1	0	0
c=Bisiklet	0	0	500	0	0
d>Koşma	0	0	1	498	1
e=Yürüme	0	0	0	0	500

**Çizelge 4.38. Rastgele Alt Uzaylar+kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	487	12	1	0	0
b=Otobüs	8	491	1	0	0
c=Bisiklet	0	0	498	1	1
d>Koşma	0	0	1	498	1
e=Yürüme	0	0	0	1	499

kNN ve bu yöntemle oluşturulan sınıflandırıcı topluluklarından elde edilen sonuçlarda ise Bagging sınıflandırıcı topluluğunda bisiklet sürme yürüme eylemlerinin %100 doğrulukla sınıflandırıldığı görülmektedir. Araba veya otobüsle seyahat etme ulaşım türleri ise Naive Bayes'e göre daha başarılı sonuçlar vermiştir (1000 örnekte yaklaşık 20 hatalı sınıflandırma).

**Çizelge 4.39. C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	484	14	2	0	0
b=Otobüs	14	486	0	0	0
c=Bisiklet	1	0	496	1	2
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	0	499

**Çizelge 4.40. AdaboostM1+C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	488	11	1	0	0
b=Otobüs	12	487	1	0	0
c=Bisiklet	2	0	496	2	0
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	1	498

**Çizelge 4.41. Bagging+C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	486	12	2	0	0
b=Otobüs	13	485	2	0	0
c=Bisiklet	1	0	496	1	2
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	1	498

**Çizelge 4.42. Rastgele Alt Uzaylar+C4.5 yöntemine ait karmaşıklık matrisi**

<b>Sınıflandırma</b>	<b>a</b>	<b>b</b>	<b>c</b>	<b>d</b>	<b>e</b>
a=Araba	486	12	1	0	1
b=Otobüs	18	482	0	0	0
c=Bisiklet	2	0	494	1	3
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	0	499

C4.5 yönteminde ise kNN yöntemine göre daha hatalı sonuçlara rastlanmıştır. kNN ve Naive Bayes yöntemlerinde araba-otobüs ve yürüme-koşma-bisiklet aktiviteleri kendi içlerinde hatalı sınıflandırmalara rastlanmıştır. Bu yöntemde ise araba ile yolculuk yapma ve bisiklet sürme aktivitelerinin de az miktar da olsa birbiri ile karıştığı görülmektedir.

**Çizelge 4.43. Rastgele Orman yöntemine ait karmaşıklık matrisi**

<b>Sınıflandırma</b>	<b>a</b>	<b>b</b>	<b>c</b>	<b>d</b>	<b>e</b>
a=Araba	485	14	1	0	0
b=Otobüs	13	486	1	0	0
c=Bisiklet	1	0	489	1	0
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	0	499

**Çizelge 4.44. AdaboostM1+Rastgele Orman yöntemine ait karmaşıklık matrisi**

<b>Sınıflandırma</b>	<b>a</b>	<b>b</b>	<b>c</b>	<b>d</b>	<b>e</b>
a=Araba	485	14	1	0	0
b=Otobüs	12	487	1	0	0
c=Bisiklet	0	0	499	1	0
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	0	499

**Çizelge 4.45. Bagging+Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	486	13	1	0	0
b=Otobüs	11	488	1	0	0
c=Bisiklet	1	0	499	0	0
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	0	499

**Çizelge 4.46. Rastgele Alt Uzaylar+Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	489	10	1	0	0
b=Otobüs	12	487	1	0	0
c=Bisiklet	0	0	495	2	3
d>Koşma	0	0	1	499	0
e=Yürüme	0	0	1	0	499


Rastgele orman ve bu yöntemle oluşturulan sınıflandırıcı toplulukları ile yüksek başarı oranları yakalanmıştır. Sınıflara göre başarı oranları diğer yöntemlere benzer olsa da bisiklet sürme aktivitesinin Rastgele alt uzaylar sınıflandırıcı topluluğu ile diğer algoritmalara göre daha hatalı sınıflandırıldığı görülmektedir. Oylama yönteminde ise 500 araba ile seyahat etme örneğinin 13 otobüs ile seyahat etme, 3 adet bisiklet sürme olarak hatalı sınıflandırıldığı görülmektedir.

**Çizelge 4.47. Oylama yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e
a=Araba	484	13	3	0	0
b=Otobüs	4	495	1	0	0
c=Bisiklet	0	0	500	0	0
d>Koşma	0	0	1	498	1
e=Yürüme	0	0	1	0	499

Karmaşıklık matrislerinin geneli ele alındığında bisiklet sürme, yürüme ve koşma aktivitelerinin her yöntemde yüksek doğrulukta sınıflandırıldığı görülmektedir. Bu sınıflar nadiren kendi içlerinde karışmaktadır. Sınıflandırma sorunu yaşanan asıl

sınıflar ise araba veya otobüs ile seyahat etme sınıflarıdır. Bu iki aktivite araç ile seyahat etme olarak adlandırılabilir. Aktivite gerçekleştirilirken sergilenen titreşim ve duruş şekli benzerlik gösterdiğinden bu iki eylemin birbiri ile karıştığı gözlemlenmiştir. Yürüme, koşma ve bisiklete binme eylemleri ise daha karakteristik titreşimlere sahip olduğundan daha başarılı sonuçlar alınmıştır. GPS algılayıcısının performansının düşük kalmasının nedeni ise araba veya otobüs ile seyahat ederken bu iki taşıtın da benzer hızlarda gidebiliyor olması ve şehir içi sıkışık trafikte ise bir yaya veya bir bisikletin hızına kadar düşebiliyor olmasından kaynaklanmaktadır. Eğri altında kalan alanlar her sınıf için hesaplanan değerlerin ortalaması alınarak elde edilmiştir. ROC eğrisi ise sınıflardan elde edilen gerçek pozitiflik oranlarının ortalaması ve yalancı pozitiflik oranlarının ortalaması alınarak çizdirilmiştir. En iyi sonucun elde edildiği Bagging+kNN yöntemine ait ROC eğrisi Şekil 4.23.'de verilmektedir

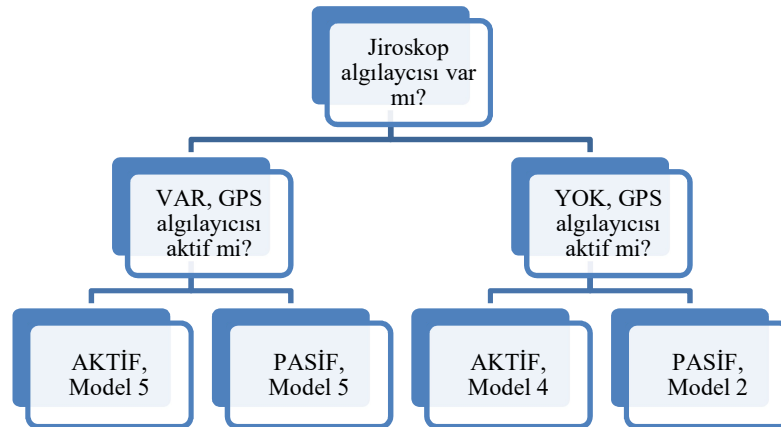


Şekil 4.23. Bagging+kNN yöntemine ait ROC eğrisi

Eğri altında kalan alanlar ve ROC eğrisi incelendiğinde başarılı sonuçların elde edildiği görülmektedir. Sınıflara göre elde edilen gerçek pozitiflik oranları ve yalancı pozitiflik oranlarının ortalaması alınarak çizdirilen ROC eğrilerinde ise kNN ve Rastgele Orman yöntemleri ve bu yöntemlerle oluşturulan sınıflandırıcı toplulukları oldukça başarılı sonuçlar vermiştir.


#### 4.2.4. Ulaşım türü tespiti için mobil uygulama geliştirilmesi

Ulaşım türlerinin anlık olarak tespit edilebilmesi için Android tabanlı mobil uygulama geliştirilmiştir. Geliştirilen Android uygulama Şekil 4.24'de gösterilen çalışma senaryosu uygulanarak sadece aktif olan algılayıcılardan veri toplanıp o algılayıcı veya algılayıcı kombinasyonunun en başarılı sonuç verdiği yöntemin kullanılacağı şekilde ayarlanmıştır. Çünkü veri seti oluşturulan akıllı telefon jiroskop algılayıcısına sahip olsa da bu algılayıcıya sahip olmayan akıllı telefonlar bulunmakta veya kullanıcı güç tasarrufu amacı ile GPS algılayıcısını kapalı durumda tutabilmektedir. Bu durumda, akıllı telefon jiroskop algılayıcısına sahipse Bagging+kNN yöntemi, jiroskop algılayıcısı pasif ve GPS algılayıcısı aktif ise Rastgele Orman yöntemi, jiroskop ve GPS algılayıcısı ikisi birden pasif durumda ise Oylama yöntemi geliştirilen uygulamada sınıflandırma hesaplamaları için kullanılmaktadır.



Şekil 4.24. Ulaşım türü sınıflandırma uygulaması çalışma senaryosu

Arka planda da çalışabilen uygulama, çalışmaya başladığı anda 12 saniyede bir desen oluşturmakta ve bunu aktif olan algılayıcı grubuna göre en yüksek doğruluk oranına sahip yöntem ile sınıflandırmaktadır. Geliştirilen uygulama, test etmek amacıyla bulunan sonuçları uygulama ara yüzünde raporlamakta ve eğer istenirse bir dakikalık aralıklara SMS gönderebilmektedir. Ulaşım türü tespitini gerçekleştiren Android uygulamanın ara yüz ekran görüntüsü Şekil 4.25’de gösterilmektedir.



Şekil 4.25. Sınıflandırma uygulaması ekran görüntüsü

### 4.3. İnsan Hareketlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi

Bu tezde gerçekleştirilen üçüncü çalışma, akıllı telefon algılayıcıları (ivmeölçer, jiroskop ve GPS) kullanılarak Şekil 4.26.’da gösterilen insan hareketlerinin (yürüme, koşma, bisiklet sürme, hareketsiz durumda olma, merdiven inme, merdiven çıkma ve asansör kullanma) tespitidir. Hareketsiz durumda olma eylemi, oturma ve ayakta durma eylemlerini içermektedir. Bu amaçla oluşturulan veri seti, öznelik seçimi,



gerçekleştirilen deneyler ve geliştirilen mobil uygulamalar aşağıdaki alt başlılarda anlatılmaktadır.



Şekil 4.26. Gerçekleştirilen insan hareketleri

#### 4.3.1. Veri seti

İnsan hareketlerinin akıllı telefon algılayıcıları ile tespit edilebilmesi amacı ile veri seti oluşturmak için “Ulaşım Türlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi” başlıklı çalışmada kullanılan akıllı telefon ve geliştirilen veri seti mobil uygulaması kullanılmıştır. Çalışmanın bu aşamasında toplamda 875000 ham algılayıcı verisi toplanmış ve 5 saniyelik pencereleme (250 veri) ayrılarak her sınıf için 500 toplamda 3500 desen (7 sınıf) ile veri seti oluşturulmuştur. İnsan hareketlerinin akıllı telefon algılayıcıları ile tespit edilmesinde hareketsiz eylemlerin bulunmasından dolayı 0 değerine sahip hız bilgileri de veri setine dâhil edilmiştir.

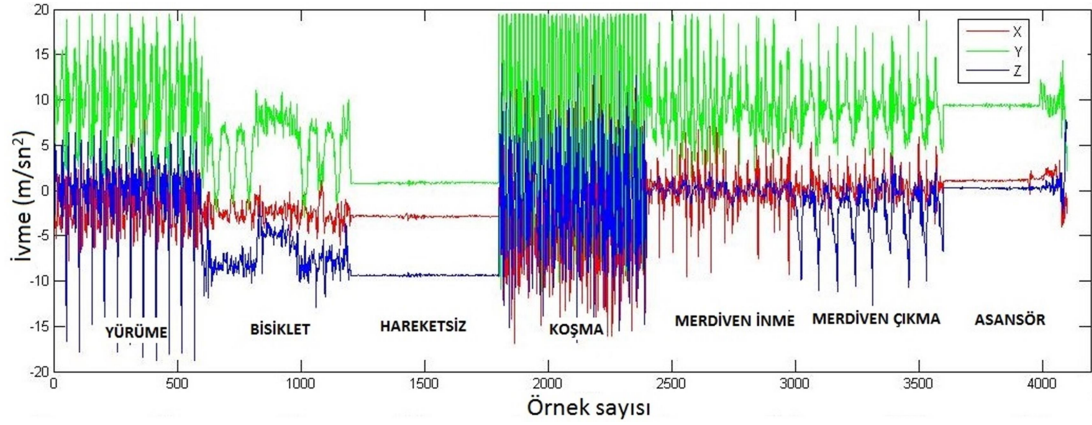
#### 4.3.2. Öznitelik seçimi

Çalışmanın bu aşamasında bölüm 4.2.’de anlatılan “Ulaşım Türlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi” başlıklı çalışma ile aynı öznitelikler seçilmiştir

(Çizelge 4.48.). Eylemlere göre örnek ivmeölçer ve jiroskop algılayıcısı verileri Şekil 4.27. ile Şekil 4.30. arasında gösterilmektedir.

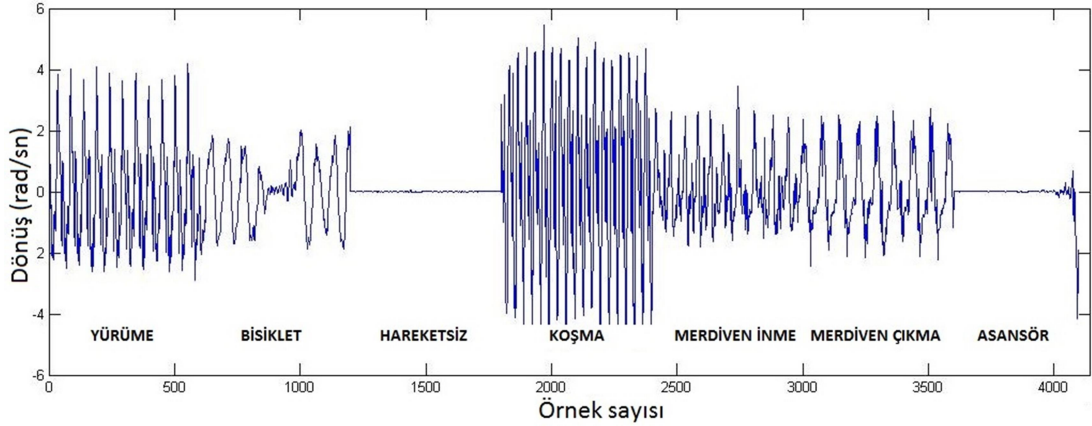
Çizelge 4.48. Ulaşım türü tespiti çalışmasında kullanılan algılayıcılar ve öznelilikler

Kullanılan Algılayıcılar	Parametreler
GPS, İvmeölçer, Jiroskop	OrtHiz, MaxHiz, AccXort, AccYort, AccZort, StdXort, StdYort, StdZort, GyrXort, GyrYort, GyrZort, GyrXstd, GyrYstd, GyrZstd

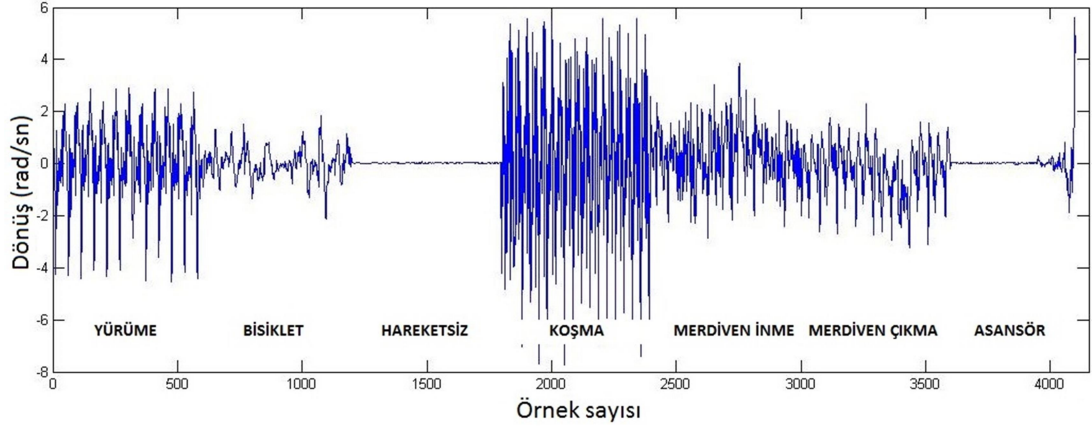


Şekil 4.27. Eylemlere göre örnek akıllı telefon ivmeölçer algılayıcısı verileri


Şekil 4.19. ve Şekil 4.27.'de kullanılan akıllı telefonun ivmeölçer hassasiyetinden dolayı  $\pm 20 \text{ m/sn}^2$  aralığının dışında kalan ivmelenmeler hesaplanamamıştır.



Şekil 4.28. Eylemlere göre akıllı telefon jiroskop algılayıcısının X eksenli örnek verileri



Şekil 4.29. Eylemlere göre akıllı telefon jiroskop algılayıcısının Y eksenini örnek verileri



Şekil 4.30. Eylemlere göre akıllı telefon jiroskop algılayıcısının Z eksenini örnek verileri

### 4.3.3. Sınıflandırma işlemi ve deneysel bulgular

Tez çalışmasının bu aşamasında akıllı telefondan elde edilen ivmeölçer, jiroskop ve GPS algılayıcıları verileri makine öğrenmesi ve sınıflandırıcı topluluğu algoritmaları kullanılarak insan hareketlerinin (yürüme, bisiklet, hareketsiz, koşma, merdiven inme, merdiven çıkma ve asansör kullanma) sınıflandırılması gerçekleştirilmiştir. Algılayıcılar arasında performans karşılaştırılması yapılabilmesi için Çizelge 4.26.'da verilen algılayıcı kombinasyonları ayrı ayrı test edilmiştir. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre sınıflandırma doğruluk oranları Çizelge 4.49.'da verilmektedir. Test sonuçlarına göre elde edilen en yüksek değer çizelgeler üzerinde kalın yazı tipi ile belirtilmiştir. Deneysel analizler k katmanlı

çapraz doğrulama test seçeneği (Weka varsayılanı olarak k değeri 10 olarak seçilmiştir) kullanılarak gerçekleştirilmiştir

**Çizelge 4.49. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre sınıflandırma doğruluk oranları**

Algoritmalar/Model	1	2	3	4	5	6
Naive Bayes	52.26	84.03	79.6	86.20	86.69	87.37
AdaBoostM1+NB	52.26	84.03	79.6	86.97	89.49	87.37
Bagging+NB	52.17	84.20	79.71	86.09	86.63	87.29
RAU+NB	51.37	81.089	79.11	84.09	86.43	87.54
kNN	54.89	93.80	89.49	93.63	97.03	96.77
AdaBoostM1+kNN	54.88	93.80	89.49	93.63	97.03	96.77
Bagging+kNN	54.66	93.71	89.74	93.51	97.14	96.91
RAU+kNN	51.80	93.34	85.49	93.29	97.49	97.23
C4.5	55.23	93.49	89.17	93.57	96.54	96.66
AdaBoostM1+C4.5	55.23	95.66	89.57	95.63	98.03	98.23
Bagging+C4.5	55.4	94.69	90.86	95.2	97.71	97.29
RAU+C4.5	53.71	94.11	87.46	94.69	97.51	97.91
Rastgele Orman	<b>56.17</b>	<b>96.03</b>	91.37	96.17	<b>98.31</b>	<b>98.49</b>
AdaBoostM1+RO	56.09	95.69	<b>91.51</b>	96.17	98.23	98.29
Bagging+RO	55.91	95.83	91.2	<b>96.20</b>	98.29	<b>98.49</b>
RAU+RO	53.77	94.63	87.71	95.20	98.26	98.17
Oylama	54.80	95.46	90.77	95.54	97.23	97.34

Çizelge 4.49. incelendiğinde her algılayıcı kombinasyonu için en başarılı sonucun Rastgele Orman (Rastgele orman, AdaboostM1+Rastgele orman, Bagging+Rastgele orman) yönteminden elde edildiği görülmektedir. Ulaşım türü sınıflandırmada olduğu gibi bu çalışmada da GPS algılayıcısı yalnız başına başarısız kalmıştır. Bunun başlıca nedeni yürüme ve bisiklet sürme eylemleri dışında diğer eylemlerin hız bilgilerinin olmamasıdır. Merdiven inme ve çıkma, asansör kullanma eylemleri bina içi eylemler olduğundan bu eylemler gerçekleştirilirken GPS sinyalleri her zaman yüksek doğrulukta elde edilememiştir. İvmeölçer algılayıcısı yalnız başına yüksek doğrulukta sınıflandırma gerçekleştirebilmiştir. Bu çalışmada ivmeölçer algılayıcısına eklenen her algılayıcı sınıflandırma doğruluğunu artırmıştır. GPS algılayıcısı eklenerek %96.2, jiroskop algılayıcısı eklenerek %98.31 doğruluk oranı

yakalanmıştır. Üç algılayıcının kombinasyonundan ise %98.49 ile en başarılı sonuç elde edilmiştir. Rastgele orman yöntemi hem tek başına hem de Bagging sınıflandırıcı topluluğu ile bu başarıyı göstermiştir. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar Çizelge 4.50.'de verilmektedir.

**Çizelge 4.50. Sınıflandırma yöntemleri ve algılayıcı modellerine göre ortalama karesel hatalar**

<b>Algoritmalar/Model</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
Naive Bayes	0.2899	0.1861	0.2255	0.1689	0.1878	0.1832
AdaBoostM1+NB	0.3253	0.2043	0.2577	0.1718	0.1539	0.167
Bagging+NB	0.2899	0.1842	0.2245	0.1682	0.1851	0.1802
RAU+NB	0.2847	0.1971	0.2383	0.1811	0.1853	0.1799
kNN	0.2905	0.1329	0.1731	0.1348	0.0920	0.0959
AdaBoostM1+kNN	0.3096	0.1329	0.1731	0.1348	0.0920	0.0959
Bagging+kNN	0.2754	0.1179	0.1502	0.1201	0.0813	0.0852
RAU+kNN	0.2848	0.1288	0.1822	0.1210	0.0835	0.0861
C4.5	0.2704	0.1314	0.1589	0.1298	0.0972	0.095
AdaBoostM1+C4.5	0.3317	0.1070	0.1656	0.1070	0.0713	0.0689
Bagging+C4.5	0.2653	0.1061	0.1433	0.1022	0.0747	0.0751
RAU+C4.5	0.2734	0.1314	0.1807	0.1222	0.0882	0.0860
Rastgele Orman	0.2664	0.0969	0.1359	0.0950	0.0674	0.0679
AdaBoostM1+RO	0.3090	0.0973	0.1368	0.0952	0.0684	0.0690
Bagging+RO	0.2652	0.0991	0.1369	0.0969	0.0708	0.0712
RAU+RO	0.2753	0.1272	0.1812	0.1172	0.0856	0.0834
Oylama	0.2659	0.1075	0.1411	0.1056	0.0807	0.0796

Doğruluk oranları incelendiğinde en yüksek oranlar Model 6 algılayıcı kombinasyonu ve Rastgele Orman yönteminden elde edilmesine rağmen Çizelge 4.50.'e göre en küçük ortalama karesel hata 0.0674 değeri ile Model 5 algılayıcı kombinasyonu ile Rastgele Orman yönteminden elde edilmiştir. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri ve eğri altında kalan ortalama alanlar Çizelge 4.51' ve Çizelge 4.52'de verilmektedir.

**Çizelge 4.51. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre elde edilen ortalama F-ölçütü değerleri**

<b>Algoritmalar/Model</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
Naive Bayes	0,441	0,840	0,782	0,860	0,853	0,862
AdaBoostM1+NB	0,441	0,840	0,782	0,867	0,886	0,862
Bagging+NB	0,440	0,842	0,784	0,859	0,853	0,862
RAU+NB	0,421	0,808	0,775	0,837	0,851	0,864
kNN	0,498	0,938	0,895	0,936	0,970	0,968
AdaBoostM1+kNN	0,498	0,938	0,895	0,936	0,970	0,968
Bagging+kNN	0,508	0,937	0,897	0,935	0,971	0,969
RAU+kNN	0,469	0,933	0,855	0,933	0,975	0,972
C4.5	0,498	0,935	0,891	0,936	0,965	0,967
AdaBoostM1+C4.5	0,498	0,957	0,896	0,956	0,980	0,982
Bagging+C4.5	0,513	0,947	0,909	0,952	0,977	0,973
RAU+C4.5	0,465	0,941	0,875	0,947	0,975	0,979
Rastgele Orman	0,512	0,960	0,914	0,962	0,983	0,985
AdaBoostM1+RO	0,511	0,957	0,915	0,962	0,982	0,983
Bagging+RO	0,520	0,958	0,912	0,962	0,983	0,985
RAU+RO	0,480	0,946	0,877	0,952	0,983	0,982
Oylama	0,500	0,955	0,908	0,955	0,972	0,973

**Çizelge 4.52. Sınıflandırma yöntemleri ve algılayıcı kombinasyonlarına göre eğri altında kalan ortalama alanlar**

Algoritmalar/Model	1	2	3	4	5	6
Naive Bayes	0,842	0,977	0,966	0,982	0,990	0,991
AdaBoostM1+NB	0,781	0,954	0,902	0,976	0,981	0,977
Bagging+NB	0,842	0,978	0,966	0,984	0,991	0,992
RAU+NB	0,840	0,973	0,931	0,981	0,988	0,987
kNN	0,838	0,964	0,939	0,963	0,983	0,981
AdaBoostM1+kNN	0,802	0,964	0,939	0,963	0,983	0,981
Bagging+kNN	0,857	0,984	0,978	0,982	0,994	0,993
RAU+kNN	0,846	0,994	0,982	0,995	0,999	0,999
C4.5	0,855	0,971	0,972	0,976	0,984	0,985
AdaBoostM1+C4.5	0,849	0,997	0,986	0,997	0,999	0,999
Bagging+C4.5	0,869	0,994	0,991	0,996	0,998	0,998
RAU+C4.5	0,853	0,995	0,987	0,995	0,999	0,999
Rastgele Orman	0,868	0,997	0,994	0,998	1,000	1,000
AdaBoostM1+RO	0,826	0,998	0,993	0,998	1,000	1,000
Bagging+RO	0,871	0,998	0,994	0,998	1,000	1,000
RAU+RO	0,855	0,996	0,988	0,997	1,000	1,000
Oylama	0,871	0,997	0,994	0,997	1,000	0,999

Eğri altında kalan alanlar yöntemlere göre 0.781 ile 1.000 arasında hesaplanmıştır. En büyük F-ölçütü değeri 0.985 değeri ile Model 6 algılayıcı kombinasyonu ve Rastgele Orman (Rastgele Orman ve Bagging+Rastgele Orman) yönteminden elde edilmiştir. En küçük F-ölçütü değeri 0.421 ile Model 1 algılayıcı kombinasyonu (Sadece GPS) ve Rastgele alt uzaylar ile Naive Bayes sınıflandırıcı topluluğundan elde edilmiştir. En yüksek doğruluk oranının elde edildiği Model 6 algılayıcı kombinasyonunun (GPS, ivmeölçer ve jiroskop) sınıflandırma yöntemlerine göre elde edilen karmaşıklık matrisleri Çizelge 4.53. ile Çizelge 4.69. arasında gösterilmektedir.

**Çizelge 4.53. Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	497	0	0	0	0	0	3
b=Hareketsiz	1	482	0	1	0	0	16
c=Koşma	0	0	499	0	0	1	0
d=Merdiven inme	0	0	0	464	35	0	1
e=Merdiven çıkma	0	0	0	48	450	0	2
f=Yürüme	0	0	0	2	1	495	2
g=Asansör	1	301	0	15	12	0	171

**Çizelge 4.54. AdaboostM1 + Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	497	0	0	0	0	0	3
b=Hareketsiz	1	482	0	1	0	0	16
c=Koşma	0	0	499	0	0	1	0
d=Merdiven inme	0	0	0	464	35	0	1
e=Merdiven çıkma	0	0	0	48	450	0	2
f=Yürüme	0	0	0	2	1	495	2
g=Asansör	1	301	0	15	12	0	171

**Çizelge 4.55. Bagging + Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	497	0	0	0	0	0	3
b=Hareketsiz	1	481	0	1	0	0	17
c=Koşma	0	0	499	0	0	1	0
d=Merdiven inme	0	0	0	460	39	0	1
e=Merdiven çıkma	0	0	0	53	446	0	1
f=Yürüme	0	0	0	2	1	495	2
g=Asansör	0	299	0	15	9	0	177



**Çizelge 4.56. Rastgele alt uzaylar + Naive Bayes yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	498	0	0	1	0	0	1
b=Hareketsiz	2	481	0	0	0	0	17
c=Koşma	0	0	499	0	0	1	0
d=Merdiven inme	0	0	0	462	37	0	1
e=Merdiven çıkma	0	0	0	44	454	0	2
f=Yürüme	1	0	0	0	0	499	0
g=Asansör	0	306	0	13	10	0	171

Çizelge 4.53. – 4.56. incelendiğinde 500 merdiven inme eyleminin yaklaşık 35 tanesinin merdiven çıkma, 500 merdiven çıkma eyleminin ise yaklaşık 50 tanesinin merdiven inme olarak hatalı sınıflandırıldığı görülmektedir. Hareketsiz bulunma eylemi ise asansör kullanma eylemi ile karıştığı gözlemlenmiştir. Bu yöntemin ortalama doğruluğunu düşüren sınıf ise asansör kullanma olduğu görülmektedir. Bu eylem yaklaşık olarak %35 doğruluk ile sınıflandırılabilmiştir. Koşma, yürüme ve bisiklet sürme eylemleri ise %100'e yakın başarı ile tespit edilmiştir.

**Çizelge 4.57. kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	499	0	0	0	0	1	0
b=Hareketsiz	1	472	0	0	0	0	27
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	483	15	0	2
e=Merdiven çıkma	0	0	0	29	470	1	0
f=Yürüme	0	0	0	1	0	499	0
g=Asansör	0	33	0	2	1	0	464

**Çizelge 4.58. AdaboostM1 + kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	499	0	0	0	0	1	0
b=Hareketsiz	1	472	0	0	0	0	27
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	483	15	0	2
e=Merdiven çıkma	0	0	0	29	470	1	0
f=Yürüme	0	0	0	1	0	499	0
g=Asansör	0	33	0	2	1	0	464

**Çizelge 4.59. Bagging + kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	499	0	0	0	0	1	0
b=Hareketsiz	0	474	0	0	0	0	26
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	483	15	0	2
e=Merdiven çıkma	0	0	0	26	473	1	0
f=Yürüme	0	0	0	1	0	499	0
g=Asansör	0	32	0	3	1	0	464

**Çizelge 4.60. Rastgele alt uzaylar + kNN yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	499	0	0	0	0	1	0
b=Hareketsiz	0	482	0	0	0	0	18
c=Koşma	0	0	499	0	0	1	0
d=Merdiven inme	0	0	0	485	14	0	1
e=Merdiven çıkma	0	0	0	28	471	1	0
f=Yürüme	0	0	0	0	0	500	0
g=Asansör	0	25	0	5	3	0	467

kNN ve sınıflandırıcı toplulukları bisiklet sürme, koşma ve yürüme eylemlerini yüksek başarı oranları ile sınıflandırmıştır. Asansör kullanma-hareketsiz bulunma ve merdiven inme-merdiven çıkma eylemlerinde ise kendi aralarında hatalı sınıflandırılmalara rastlanmıştır.

**Çizelge 4.61. C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	496	1	1	0	0	2	0
b=Hareketsiz	0	476	0	0	0	0	24
c=Koşma	0	0	500		0	0	0
d=Merdiven inme	0	0	0	482	11	2	5
e=Merdiven çıkma	0	0	0	14	481	1	4
f=Yürüme	0	0	0	0	4	494	2
g=Asansör	4	32	0	5	4	1	454

**Çizelge 4.62. AdaboostM1 + C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	499	1	0	0	0	0	0
b=Hareketsiz	0	486	0	0	0	0	14
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	492	6	0	2
e=Merdiven çıkma	1	0	0	8	490	0	1
f=Yürüme	1	0	0	0	2	497	0
g=Asansör	2	18	0	5	1	0	474

**Çizelge 4.63. Bagging + C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	497	1	1	0	0	1	0
b=Hareketsiz	0	475	0	0	0	0	25
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	479	13	1	7
e=Merdiven çıkma	1	0	0	16	481	0	2
f=Yürüme	1	0	0	0	2	497	0
g=Asansör	2	13	0	6	2	1	476

**Çizelge 4.64. Rastgele alt uzaylar + C4.5 yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	498	0	1	0	0	1	0
b=Hareketsiz	0	488	0	0	0	0	12
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	483	15	0	2
e=Merdiven çıkma	1	0	1	14	482	0	2
f=Yürüme	1	0	0	1	0	498	0
g=Asansör	2	14	0	2	4	0	478

C4.5 ve bu yöntemle oluşturulan sınıflandırıcı topluluklarından elde edilen sonuçlar kNN yönteminden elde edilen sonuçlarla benzerlik göstermektedir. Bu yöntemde merdiven inme ve merdiven çıkma eylemlerinin daha başarılı sınıflandırıldığı görülmektedir. Bu da J48 yönteminin ortalama doğruluk oranını artırmaktadır.

**Çizelge 4.65. Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	500	0	0	0	0	0	0
b=Hareketsiz	0	485	0	0	0	0	15
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	493	6	0	1
e=Merdiven çıkma	1	0	0	10	489	0	0
f=Yürüme	1	0	0	0	2	497	0
g=Asansör	1	10	0	2	4	0	483

**Çizelge 4.66. AdaboostM1 + Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	500	0	0	0	0	0	0
b=Hareketsiz	0	484	0	0	0	0	16
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	493	6	0	1
e=Merdiven çıkma	0	0	0	11	488	0	1
f=Yürüme	1	0	0	0	2	497	0
g=Asansör	1	12	0	5	4	0	478

**Çizelge 4.67. Bagging + Rastgele Orman yöntemine ait karmaşıklık matrisi**

Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	500	0	0	0	0	0	0
b=Hareketsiz	0	485	0	0	0	0	15
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	494	5	0	1
e=Merdiven çıkma	1	0	0	9	490	0	0
f=Yürüme	1	0	0	0	1	498	0
g=Asansör	1	11	0	3	5	0	480

**Çizelge 4.68. Rastgele alt uzaylar + Rastgele Orman yöntemine ait karmaşıklık matrisi**


Sınıflandırma	a	b	c	d	e	f	g
a=Bisiklet	498	0	0	0	0	2	0
b=Hareketsiz	0	480	0	0	0	0	20
c=Koşma	0	0	499	0	0	1	0
d=Merdiven inme	0	0	0	490	9	0	1
e=Merdiven çıkma	1	0	0	10	487	1	1
f=Yürüme	1	0	0	0	1	498	0
g=Asansör	1	11	0	1	3	0	484

En yüksek doğruluk oranına sahip Rastgele Orman yöntemi ile bisiklet sürme ve koşma eylemlerinin %100 başarı ile sınıflandırıldığı görülmektedir. Merdiven inme, merdiven çıkma, hareketsiz bulunma ve asansör kullanma gibi birbiri ile çok fazla karışan eylemlerin bu yöntemde hatalı sınıflandırılmaları en düşük duruma gelmiştir. Oylama yönteminin ise Rastgele Orman yöntemine göre, asansör kullanma eyleminin sınıflandırma başarısının daha düşük olduğu gözlemlenmektedir.

**Çizelge 4.69. Oylama yöntemine ait karmaşıklık matrisi**

<b>Sınıflandırma</b>	<b>a</b>	<b>b</b>	<b>c</b>	<b>d</b>	<b>e</b>	<b>f</b>	<b>g</b>
a=Bisiklet	499	0	0	0	0	1	0
b=Hareketsiz	1	484	0	0	0	0	15
c=Koşma	0	0	500	0	0	0	0
d=Merdiven inme	0	0	0	490	8	0	2
e=Merdiven çıkma	0	0	0	12	486	0	2
f=Yürüme	0	0	0	0	1	499	0
g=Asansör	1	45	0	3	2	0	499


Karmaşıklık matrislerinin geneline göre yürüme, bisiklet sürme ve koşma eylemlerinin %100'e yakın doğrulukta sınıflandırıldığı görülmektedir. Merdiven inme eylemi en çok merdiven çıkma eylemi ile karışmıştır. Asansör kullanma eylemi ise en çok hareketsiz durma eylemi ile karışmıştır. Bunun nedeni asansör kullanan insanın asansör içerisinde sadece ayakta duruyor olması ve eyleme ait karakteristik bir özelliğinin olmamasından kaynaklanmaktadır. Asansör kullanma eylemi Naive Bayes ve Naive Bayes ile oluşturulan sınıflandırıcı topluluklarında hatalı sınıflandırılması %50'nin üzerinde seyretmektedir. Bu nedenle Naive Bayes yönteminin sınıflandırma performansı ciddi oranda düşmektedir. GPS algılayıcısı genel sınıflandırma oranını yükseltmiş olsa da, eylemlerin çoğunun (asansör, merdiven inme, merdiven çıkma ve hareketsiz bulunma) bina içi eylemler olmasından dolayı jiroskop algılayıcısının başarısını göstermemiştir. Eğri altında kalan alanlar her sınıf için hesaplanan değerlerin ortalaması alınarak elde edilmiştir. ROC eğrisi ise sınıflardan elde edilen gerçek pozitiflik oranlarının ortalaması ve yalancı pozitiflik oranlarının ortalaması alınarak çizdirilmiştir. En iyi sonucun elde edildiği Rastgele Orman yöntemine ait ROC eğrisi Şekil 4.31.'de verilmektedir



Şekil 4.31. Rastgele Orman yöntemine ait ROC eğrisi

#### 4.3.4. Akıllı telefon için eylem tanıma için mobil uygulama geliştirilmesi

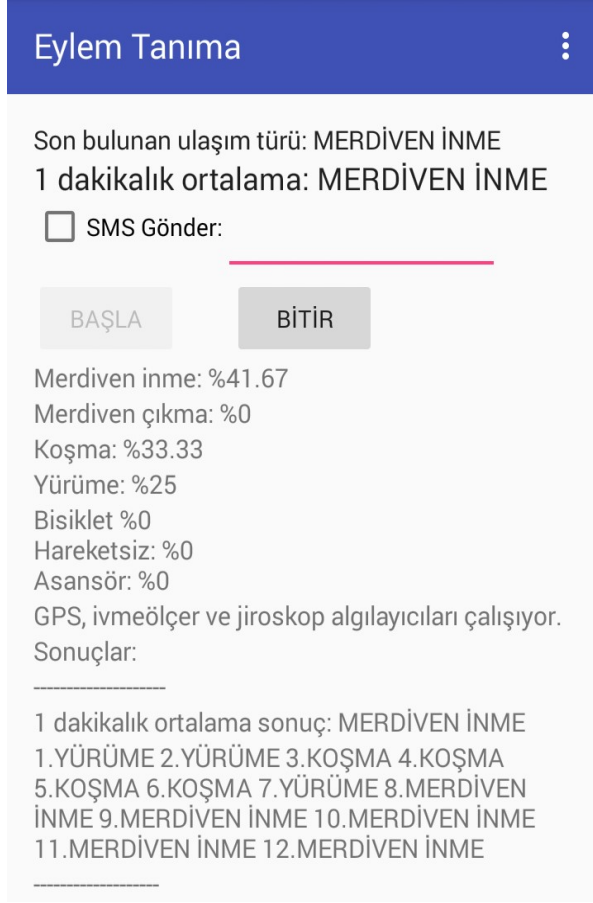
Akıllı telefon algılayıcıları ile insan hareketlerinin tespit edildiği mobil uygulama, akıllı telefonun sahip olduğu algılayıcılara göre Şekil 4.32.'de verilen çalışma senaryosuna göre işlem yapmaktadır. Bu sayede aktif olan algılayıcılara göre en uygun yöntem seçilerek en doğru tespitin gerçekleştirilmesi sağlanmaktadır. Bu durumda, akıllı telefon jiroskop algılayıcısına sahip değilse ve GPS algılayıcısı aktif durumda ise Bagging+Rastgele Orman yöntemi, diğer durumlarda ise Rastgele Orman yöntemi geliştirilen uygulamada sınıflandırma hesaplamaları için kullanılmaktadır.



**Şekil 4.32. İnsan hareketlerinin sınıflandırılması uygulamasının çalışma senaryosu**

Arka planda da çalışabilen uygulama, çalışmaya başladığı anda 5 saniyede bir desen oluşturmakta ve bunu aktif olan algılayıcı grubuna göre en yüksek doğruluk oranına sahip yöntem ile değerlendirmektedir. Geliştirilen uygulama, bölüm 4.2.'de anlatılan "Ulaşım Türlerinin Akıllı Telefon Algılayıcıları ile Tespit Edilmesi" başlıklı çalışmada olduğu gibi test etmek amacıyla bulunan sonuçları uygulama ara yüzünde raporlamakta ve eğer istenirse bir dakikalık aralıklara SMS gönderebilmektedir. Eylem tanıma gerçekleştiren Android uygulamanın ara yüz ekran görüntüsü Şekil 4.33.'de gösterilmektedir.





**Şekil 4.33. Eylem tanıma uygulaması ekran görüntüsü**

## 5. SONUÇLAR

Bu tez çalışmasında gündelik insan hareketleri ve kişilerin kullandığı ulaşım araçlarının akıllı telefon ve akıllı saat algılayıcı verileri kullanılarak tespit edilmesi ve sınıflandırılması konusu araştırılmıştır. Sınıflandırma aşamasında makine öğrenmesi yöntemlerinin ve sınıflandırıcı topluluklarının performansları karşılaştırılmıştır. Çalışmada kullanılacak algılayıcı verilerini elde etmek ve çevrimiçi sınıflandırma gerçekleştirebilmek için akıllı telefon ve akıllı saat üzerinde çalışabilen Android ve Android Wear tabanlı mobil uygulamalar geliştirilmiştir.

Algılayıcı grupları ve sınıflandırma yöntemlerine göre gerçekleştirilen tüm çalışmaların doğruluk oranları %51.8 ile %99.2 arasında değişmektedir. Gerçekleştirilen üç ayrı aktivite sınıflandırma çalışmasında da yalnızca ivmeölçer algılayıcısı ile yüksek doğrulukta sonuçlar elde edilmiştir. Akıllı telefon ile ulaşım türü sınıflandırılmasında jiroskop, akıllı telefon ile insan hareketlerinin sınıflandırılmasında jiroskop ve GPS, akıllı saat ile insan hareketlerinin sınıflandırılması çalışmasında ise jiroskop, adımsayar ve kalp hızı algılayıcıları doğruluk oranlarını anlamlı bir şekilde artırmıştır.

İnsan hareketlerinin sınıflandırılması konusunda akıllı saat ile gerçekleştirilen çalışmada akıllı telefon ile gerçekleştirilen çalışmaya göre daha yüksek doğruluk oranına ulaşılmıştır. Bunun sebebi, akıllı saatin sahip olduğu adımsayar ve kalp hızı algılayıcılarının sınıflandırma başarısına katkı sağlamasıdır. Akıllı saatin ve akıllı telefonun ortak algılayıcısı olan ivmeölçer algılayıcısı ele alındığında saat ile yapılan çalışmada %98'in üzerinde doğruluk oranı yakalanırken telefon ile yapılan çalışmada bu oran %96'larda kalmaktadır. Jiroskop algılayıcısı ise başarı oranını akıllı telefon ile yapılan çalışmada daha fazla artırmıştır. Saat ile yapılan çalışmada jiroskop

algılayıcısı doğruluk oranını %0.5 artırırken, telefon ile yapılan çalışmada yaklaşık %2.5 artırmıştır.

Sınıflandırma yöntemlerinde ise Bagging sınıflandırıcı topluluğunun, oluşturulan veri seti için uygun olduğu görülmektedir. Akıllı telefon ile insan hareketlerinin sınıflandırılmasında Rastgele Orman yönteminden, akıllı saat ile insan hareketlerinin sınıflandırılmasında ise kNN yönteminden daha iyi sonuçlar alınmasını sağlamıştır. Ek olarak ulaşım türü sınıflandırılmasında da en iyi sonuç kNN yönteminin Bagging sınıflandırıcı topluluğu ile kullanılmasından elde edilmiştir. Sınıflandırıcı topluluklarından Oylama yöntemi sadece akıllı telefon ile ulaşım türü sınıflandırması çalışmasında sadece ivmeölçer algılayıcı ile yapılan çalışmada en başarılı yöntem olarak öne çıkmıştır. Bunlara ek olarak Naive Bayes yöntemi ve bu yöntem ile oluşturulan sınıflandırıcı toplulukları çalışmanın hiçbir aşamasında en başarılı yöntem olamamışlardır.

Aktivite tespiti uygulamaları, sağlıklı yaşam konusunda insanlara destek olabilmektedir. Yaşlı insanların ve küçük çocukların düşmesi veya kaybolması, bunun yanı sıra bir sınıfta gençlik otizm spektrum bozukluğu gibi tehlikeli eylemlerin algılanmasını ve bu kötü durumların önlenmesini sağlayabilir. Bu uygulamalar ayrıca günlük yaşamda kullanıcıya uyarıcı bir şekilde yardımcı olabilir. Örneğin, kullanıcı için sağlıklı bir spor alışkanlığı oluşturmak amacıyla akıllı telefon kullanıcısı çok uzun süre hareketsiz kaldığı durumlarda bir hatırlatma gönderebilir. Bu tip uygulamalar insanların ne kadar yürüdükleri, kaç basamak çıktıkları, ne kadar süre uydukları gibi bilgileri takip edebilmektedir. Ayrıca giyilebilir akıllı cihazlarla gerçekleştirilen aktivite tespiti ile son zamanlarda popülerliği git gide artan sanal gerçeklik uygulamalarına insan simülasyonunun eklenerek bu uygulamaların daha kapsamlı bir hal alması sağlanacaktır. Bu sebeple insan aktivitelerin yüksek doğrulukta sınıflandırılması çok büyük önem arz etmektedir.

Gelecek çalışmalarda aktivite sınıflandırma çalışmaları çeşitli yollarla geliştirilebilir. Bunlardan birincisi sınıf sayısını artırarak daha net sonuçlar elde etmektir. Ulaşım

türü sınıflandırması için yeraltı treni, motosiklet, arazi taşıtı ve hafif raylı sistem vs. insan hareketlerinin sınıflandırılması için yemek yeme, sigara içme, yemek yapma, el sallama, el sıkışma vb. sınıflar eklenebilir. Bu sayede bireyin beslenme takibi, kötü alışkanlıkların tespiti ve kullanım sıklığı gibi aktiviteler de takip edilebilecektir. Ayrıca, eylemleri daha küçük parçalara ayırarak sınıflandırma yapmak daha sağlıklı sonuçların alınmasını sağlayacaktır. Örneğin birey elleri cebinde yürüyebileceği gibi ellerini sallayarak veya bir eşya taşıyarak da yürüyebilmektedir. Eylem tanıma mobil uygulaması geliştirilirken daha küçük pencerelerde sınıflandırmaların gerçekleştirilmesi ve sonrasında akıllı telefonlarla ulaşım türü tespiti çalışmasında olduğu gibi ortalama alınarak veya kümeleme yapılarak eylem karar verilmesi ile eylemler arası geçişlerde meydana gelebilecek hatalı sınıflandırmaların önüne geçilebilecektir. Çalışmayı geliştirmek için yapılabilecek bir diğer uygulama ise veri seti oluşturulurken daha çok kullanıcıdan verilerin elde edilmesidir. Eylemler gerçekleştirilirken bireyin sergilediği duruş ve özellikle kalp hızı kişiden kişiye değişebilmektedir. Ayrıca sağlık uygulamaları geliştirilirken kullanıcıdan yaş, boy ve kilo gibi veriler alınarak tahmini yakılan kalori miktarı gibi bilgiler de hesaplanabilir.

## KAYNAKLAR

- Alan, H. F., Arnrich, B., Ersoy, C., ve Cinaz, B. (2014) Sensor Log: A mobile data collection and annotation application, *Signal Processing and Communications Applications Conference (SIU)*, 23-25 Nisan 2014, Trabzon, Türkiye, Cilt: 1375-1378
- Amasyalı, M.F., ve Ersoy, O. (2011) Sınıflandırıcı Topluluklarında Başarı Tabanlı Budama ve Ağırlıklı Oylama, *audiology*, 70(5): 169-172.
- Ayabakan, T. (2014) *Dönüölçer ve Deönüölçerli Dengeleyiciler*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul, 98s.
- Ballı, S. (2016) A data mining approach to the diagnosis of failure modes for two serial fastened sandwich composite plates, *Journal Of Composite Materials*, Baskıda.
- Ballı, S., ve Sağbaşı, E.A. (2016) The Usage of Statistical Learning Methods on Wearable Devices and a Case Study: Activity Recognition on Smartwatches, *Advances in Statistical Methodologies and Their Applications to Real Problems*, InTech, Rijeka, Croatia, Baskıda.
- Batmaz, B., Çelik, Z., Bayılmış, C., ve Kırbaşı, İ. (2015). Akıllı Telefon Temelli Birey Takip Sistemi. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 19(1): 75-82.
- Bolbol, A., Cheng, T., Tsapakis, I. ve Haworth, J. (2012) Inferring hybrid transportation modes from sparse GPS data using a moving window SVM classification, *Computers, Environment and Urban Systems*, 36: 526–537
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2): 123-140.
- Breiman, L. (2001) Random forests. *Machine learning*, 45(1): 5-32.

- Chandra, B., Gupta, M., ve Gupt, M.P. (2007) Robust approach for estimating probabilities in Naive-Bayes classifier, *In Pattern Recognition and Machine Intelligence*, 18-22 December 2007, Kolkata, India, Cilt: 11-16.
- Chernbumroong, S., Atkins, A. S., ve Yu, H. (2011) Activity classification using a single wrist-worn accelerometer. *In Software, Knowledge Information*, 8-11 September 2011, Benevento Italy, Cilt: 1-6.
- Coskun, D., Incel, O. D., ve Ozgovde, A. (2014). Position-aware activity recognition on mobile phones. *Signal Processing and Communications Applications Conference (SIU)*, 23-25 Nisan 2014, Trabzon, Türkiye, Cilt: 1930-1933
- Çınar, S. (2005) *GPS ile Araç Takip ve Yönlendirme Sistemi*, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Ankara, 96s.
- Dadashi, F., Arami, A., Crettenand, F., Millet, G. P., Komar, J., Seifert, L., ve Aminian, K. (2013) A hidden Markov model of the breaststroke swimming temporal phases using wearable inertial measurement units. *In Body Sensor Networks*, 6-9 May 2013, MIT, Cambridge, USA, Cilt: 1-6.
- da Silva, F. G., ve Galeazzo, E. (2013) Accelerometer based intelligent system for human movement recognition. *In Advances in Sensors and Interfaces*, 13-14 June 2013, Bari Italy, Cilt: 20-24.
- de la Vega, L.G.M., Raghuraman, S., Balasubramanian, A., ve Prabhakaran, B. (2013) Exploring unconstrained mobile sensor based human activity recognition, *3rd International Workshop on Mobile Sensing*, 8 Nisan 2013, Philadelphia, PA, USA, Cilt: 1-5
- Dietterich, T. G. (2000). Ensemble methods in machine learning. *In International workshop on multiple classifier system*. 21-23 June 2000, Cagliari, Italy, Cilt: 1-15
- Doğan, E. (2013) *Efficient Feature Selection for Online Activity Recognition on Smart Phones*, Yüksek Lisans Tezi, Boğaziçi Üniversitesi, İstanbul, 100s.
- Dong, Y., Scisco, J., Wilson, M., Muth, E., ve Hoover, A. (2014) Detecting periods of eating during free-living by tracking wrist motion. *Biomedical and Health Informatics*, 18(4): 1253-1260.

- Ellis, K., Godbole, S., Marshall, S., Lanckriet, G., Staudenmayer, J. ve Kerr, J. (2014) Identifying active travel behaviors in challenging environments using GPS, accelerometers, and machine learning algorithms, *Frontiers in Public Health*, 2, Article 36: 1-8
- El-Rabbany A. *Introduction to GPS: The Global Positioning System*. 2nd ed. Norwood, USA, Artech House, 2002.
- Feng, T. ve Timmermans, H.J.P (2013a) Transportation mode recognition using GPS and accelerometer data, *Transportation Research Part C: Emerging Technologies*, 37: 118–130
- Feng, T. ve Timmermans, H.J.P (2013b) Comparative evaluation of algorithms for GPS data imputation, *Proceedings of WCTR*, 15-18 Temmuz 2013, Rio de Janeiro, Brazil, Cilt: 1-11
- Freund, Y., ve Schapire, R. E. (1996). Experiments with a new boosting algorithm, *In Icml*, 96: 148-156.
- Garner, S. R. (1995). Weka: The waikato environment for knowledge analysis. *In Proceedings of the New Zealand computer science research students conference*. Hamilton, New Zealand, Cilt: 57-64.
- Guiry, J. J., van de Ven, P., ve Nelson, J. (2014) Multi-sensor fusion for enhanced contextual awareness of everyday activities with ubiquitous devices. *Sensors*, 14(3): 5687-5701.
- Györbíró, N., Fábíán, Á., ve Hományi, G. (2009). An activity recognition system for mobile phones. *Mobile Networks and Applications*, 14(1): 82-91.
- Hemminki, S., Nurmi, P. ve Tarkoma, S. (2013) Accelerometer-based transportation mode detection on smartphones. *Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems*, 11-14 November 2013, Rome, Italy, Cilt: 13-27
- Ho, T. K. (1998). Nearest neighbors in random subspaces. *In Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition*

(SPR) and Structural and Syntactic Pattern Recognition (SSPR), 11-13 August 1998, Sydney, Australia, Cilt: 640-648.

- Kansiz, A.O., ve Güvensan, M.A. (2013). Mobil telefon ile kaza tespiti accident recognition using mobile phone. *In Signal Processing and Communications Applications Conference (SIU)*, 24-26 Nisan 2013, Lefkoşa, KKTC, Cilt: 1-4.
- Khan, A.M., Lee, Y.K., ve Kim, T.S. (2008) Accelerometer signal-based human activity recognition using augmented autoregressive model coefficients and artificial neural nets. *Engineering in Medicine and Biology Society*, 20-25 August 2008, Vancouver Canada, Cilt: 5172-5175
- Khan, A. M., Tufail, A., Khattak, A. M., ve Laine, T. H. (2014). Activity recognition on smartphones via sensor-fusion and kda-based svms. *International Journal of Distributed Sensor Networks*, Cilt: 1-14.
- Kohavi, R., ve Provost, F. (1998). *Glossary of terms*. Machine Learning, 30(2-3): 271-274.
- Kökcü, B.N., Köse, R.D., Bulut, F., ve Amasyalı, M.F. (2014) Kolektif Öğrenme Algoritmalarıyla Çocuklarda Obezite Hastalığına Yakalanma Olasılıklarının Hesaplanması, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, 9-10 Ekim 2014, İzmir, Türkiye, Cilt: 200-205
- Köktürk, F. (2012) *K-En Yakın Komşuluk, Yapay Sinir Ağları ve Karar Ağaçları Yöntemlerinin Sınıflandırma Başarılarının Karşılaştırılması*, Doktora Tezi, Bülent Ecevit Üniversitesi, Zonguldak, 77s.
- Köse, M., Incel, O. D. ve Ersoy, C. (2012). Online human activity recognition on smart phones. *Workshop on Mobile Sensing: From Smartphones and Wearables to Big Data*, 16 Nisan 2012, Beijing China, Cilt: 11-15
- Köse, M., (2012) *Performance Evaluation of Classification Methods for Online Activity Recognition on Smart Phones*, Yüksek Lisans Tezi, Boğaziçi Üniversitesi, İstanbul, 87s.
- Kuncheva, L. I. (2004). *Combining pattern classifiers: methods and algorithms*. John Wiley & Sons, Hoboken, New Jersey, 350s.



- Kurban, O.C., ve Yildirim, T. (2014) Neural network based daily activity recognition without feature extraction. *Signal Processing and Communications Applications Conference (SIU)*, 23-25 Nisan 2014, Trabzon, Türkiye, Cilt: 567-570
- Kwapisz, J. R., Weiss, G. M. ve Moore, S. A. (2011) Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2): 74-82.
- Lane, N.D., Mohammad, M., Lin, M., Yang, X., Lu, H., Ali, S., Doryab, A., Berke, E., Choudhury, T. ve Campell, A.T., (2012), Bewell: A smartphone application to monitor, model and promote wellbeing, *5th International ICST Conference on Pervasive Computing Technologies for Healthcare*, 23-26 Mayıs 2011, Dublin, Ireland, Cilt: 23-26.
- Lara, O. D., Pérez, A. J., Labrador, M. A. ve Posada, J. D. (2012) Centinela: A human activity recognition system based on acceleration and vital sign data, *Pervasive and mobile computing*, 8(5): 717-729.
- Mortazavi, B. J., Pourhomayoun, M., Alsheikh, G., Alshurafa, N., Lee, S. I., ve Sarrafzadeh, M. (2014) Determining the single best axis for exercise repetition recognition and counting on smartwatches. *In Wearable and Implantable Body Sensor Networks*, 16-19 Haziran 2014, Zürich Switzerland, Cilt: 33-38.
- Onan, A., Korukoğlu, S., ve Bulut, H. (2016). Ensemble of keyword extraction methods and classifiers in text classification. *Expert Systems with Applications*, 57: 232-247.
- Özkan, Y., ve Selçukcan Erol, Ç. (2015) *Biyoenformatik DNA Mikrodizi Veri Madenciliği*, Papatya Yayıncılık Eğitim, İstanbul, 432s.
- Parkka, J., Ermes, M., Antila, K., van Gils, M., Manttari, A., ve Nieminen, H. (2007) Estimating intensity of physical activity: a comparison of wearable accelerometer and gyro sensors and 3 sensor locations. *In Engineering in Medicine and Biology Society*, 23-26 August 2007, Lyon France, Cilt: 1511-1514.
- Ramos-Garcia, R. I., ve Hoover, A. W. (2013) A study of temporal action sequencing during consumption of a meal. *In Proceedings of the*

*International Conference on Bioinformatics*, 11-14 February 2013, Barcelona Spain, Cilt: 68-75.

Ravi, N., Dandekar, N., Mysore, P. ve Littman, M.L. (2005). Activity recognition from accelerometer data. *AAAI*, 5: 1541-1546.

Reddy, S., Burke, J., Estrin, D., Hansen, M. ve Srivastava, M. (2008) Determining Transportation Mode On Mobile Phones, *Wearable Computers*, Cilt: 25-28

Riboni, D., ve Bettini, C. (2011). COSAR: hybrid reasoning for context-aware activity recognition. *Personal and Ubiquitous Computing*, 15(3): 271-289.

Rokach, L. (2010). Ensemble-based classifiers. *Artificial Intelligence Review*, 33(1-2): 1-39

Ronao, C.A., ve Cho, S.B. (2016) Human activity recognition with smartphone sensors using deep learning neural networks. *Expert Systems with Applications*, 59: 235-244.

Sağbaşı E.A, ve Ballı, S. (2015) Akıllı Telefon Sensörlerinin Kullanımı ve Ham Sensör Verilerine Erişim, *Akademik Bilişim Konferansı*, 4-6 Şubat 2015, Eskişehir, Türkiye, Cilt: 158-164

Sağbaşı, E.A, ve Ballı, S. (2016a) Akıllı Telefon Sensör Verileri ile Eylem Tanımda Lojistik Regresyon ve kNN Yöntemlerinin Karşılaştırılması, *1st International Conference on Engineering Technology and Applied Sciences*, 21-22 April 2016, Afyonkarahisar, Turkey, Cilt: 894-899

Sağbaşı, E.A, ve Ballı, S. (2016b) Akıllı Telefon Algılayıcıları Ve Makine Öğrenmesi Kullanılarak Ulaşım Türü Tespiti, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22(5): 376-383

Sağbaşı, E.A, ve Ballı, S. (2016c) İnsan Aktivitelerinin Bilek Hareketleri Kullanılarak Tahmin Edilmesi, 3. International Management Information Systems Conference, 6-8 October 2016, İzmir, Turkey, Cilt: 52-58

- Sağbaşı E.A., Ballı, S., ve Yıldız, T. (2016) Giyilebilir Akıllı Cihazlar: Dünü, Bugünü ve Geleceği, *Akademik Bilişim Konferansı*, 3-5 Şubat 2016, Aydın, Türkiye, Baskıda. (<http://ab.org.tr/ab16/bildiri/243.pdf>)
- Scholl, P. M., ve Van Laerhoven, K. (2012) A feasibility study of wrist-worn accelerometer based detection of smoking habits. *In Innovative Mobile and Internet Services in Ubiquitous Computing*, 4-6 Temmuz 2012, Palermo, Italy, Cilt: 886-891
- Shin, D., Aliaga, D., Tunçer, B., Arisona, S. M., Kim, S., Zünd, D. ve Schmitt, G. (2014). Urban sensing: Using smartphones for transportation mode classification, *Computers, Environment and Urban Systems*, 53: 76-86
- Shoaib, M., Bosch, S., Incel, O. D., Scholten, H. ve Havinga, P. J. (2014) Fusion of smartphone motion sensors for physical activity recognition. *Sensors*, 14(6): 10146-10176.
- Shoaib, M., Bosch, S., Scholten, H., Havinga, P. J., ve Incel, O. D. (2015) Towards detection of bad habits by fusing smartphone and smartwatch sensors. *In Pervasive Computing and Communication Workshops*, 23-27 Mart 2015, St. Louis, Missouri, USA, Cilt: 591-596.
- Sökün, H., Kalkan, H., Cetişli, B. (2012) İvmeölçer Sinyalleri ile Fiziksel Aktivitelerin Sınıflandırılması, *Signal Processing and Communications Applications Conference*, 18-20 Nisan 2012, Muğla, Türkiye, Cilt: 1-4
- Stenneth, L., Wolfson, O., Yu, F.S. ve Xu, B. (2010) Transportation Mode Detection using Mobile Phones and GIS Information, *Proceedings of the 19th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 1-4 Kasım 2011, Chicago, IL, USA, Cilt: 54-63
- Su, X, Tong, H, ve Ji, P. (2014) Activity recognition with smartphone sensors, *Tsinghua Science and Technology*, 19(3): 235-249.
- Toplan, E., Üstev, Y. E., İncel, Ö. D. ve Ersoy, C. (2013) Eylem Tanıma ile Şehir Dinamiklerini Elde Etmek, *Akademik Bilişim Konferansı*, 23-25 Ocak 2013, Antalya, Türkiye, (Web: <http://ab.org.tr/ab13/bildiri/98.pdf>)

- Trost, S. G., Zheng, Y., ve Wong, W. K. (2014) Machine learning for activity recognition: hip versus wrist data. *Physiological measurement*, 35(11): 2183-2189.
- Wang, S., Chen, C. ve Ma, J. (2010). Accelerometer based transportation mode recognition on mobile phones. *Wearable Computing Systems (APWCS)*, Cilt: 44-46
- Web-1: [https://courses.cs.washington.edu/courses/cse573/12au/projects/ActivityRec/ActivityRec\\_report.pdf](https://courses.cs.washington.edu/courses/cse573/12au/projects/ActivityRec/ActivityRec_report.pdf), Eriřim: 27.11.2015
- Web 2: Sensor Data, [http://wavefrontlabs.com/Wavefront\\_Labs/Sensor\\_Data.html](http://wavefrontlabs.com/Wavefront_Labs/Sensor_Data.html), Eriřim: 28.10.2016
- Web 3: <http://web.stanford.edu/class/cs75n/Sensors.pdf>, Eriřim: 28.10.2016
- Web 4: <https://www.uni-weimar.de/kunst-und-gestaltung/wiki/images/Zeitmaschinen-smartphonesensors.pdf>, Eriřim: 28.10.2016
- Web 5: <https://tr.wikipedia.org/wiki/Jiroskop>, Eriřim: 28.10.2016
- Web-6: <https://developer.android.com/reference/android/hardware/Sensor.html>, Eriřim: 07.10.2016
- Web-7: <http://mohdaslam.com/pedometer-and-step-counter-mobile-apps-how-does-it-work/>, Eriřim: 07.10.2016
- Web-8: <http://valencell.com/blog/2015/10/optical-heart-rate-monitoring-what-you-need-to-know/>, Eriřim: 07.10.2016
- Web-9: <https://www.motorola.com/us/products/moto-360>, Eriřim: 16.10.2016
- Web-10: [http://www.samsung.com/hk\\_en/consumer/mobile/smartphones/galaxy-note/GT-N7100TADTGY](http://www.samsung.com/hk_en/consumer/mobile/smartphones/galaxy-note/GT-N7100TADTGY), Eriřim: 16.10.2016

- Web-11: <https://weka.wikispaces.com/Use+WEKA+in+your+Java+code>, Erişim: 16.10.2016
- Wang, H., Lai, T. T. T., ve Roy Choudhury, R. (2015) Mole: Motion leaks through smartwatch sensors. *In Proceedings of the 21st Annual International Conference on Mobile Computing and Networking*, 7-11 Eylül 2015, Paris France, Cilt: 155-166.
- Widhalm, P., Nitsche, P. ve Brandie, N. (2012). Transport mode detection with realistic Smartphone sensor data. *Pattern Recognition (ICPR)*, Cilt: 573-576
- Witten, I.H., and Frank, E. (2005) *Data mining: Practical machine learning tools and techniques*. CA: Morgan Kaufmann Publishers, San Francisco, CA: Morgan Kaufmann Publishers, 524s.
- Wu, J., Jiang, C., Houston, D., Baker, D. ve Delfino, R. (2011) Automated time activity classification based on global positioning system (GPS) tracking data, *Environmental Health*, 10: 101-113
- Xia, H., Qiao, Y., Jian, J. ve Chang, Y. (2014). Using smart phone sensors to detect transportation modes. *Sensors*, 14(11): 20843-20865.
- Yang, J. Y., Wang, J. S., ve Chen, Y. P. (2008) Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers, *Pattern recognition letters*, 29(16): 2213-2220.
- Zheng, Y., Liu, L., Wang, L. ve Xie, X. (2008). Learning transportation mode from raw gps data for geographic applications on the web. *Proceedings of the 17th international conference on World Wide Web*, 21-25 Nisan 2008, Beijing, China, Cilt: 247-256

# ÖZGEÇMİŞ

## 1. KİŞİSEL BİLGİLER

Ad Soyad : Ensar Arif SAĞBAŞ  
Uyruk : T.C.  
Doğum Yeri ve Tarihi: Genç- 26.10.1990  
Medeni Hali : Evli  
Telefon : 0 252 211 1728  
E-posta : arifsagbas@mu.edu.tr

## 2. EĞİTİM

Öğrenim Dönemi	Derece (*)	Üniversite	Öğrenim Alanı
2014 - 2016	Yüksek Lisans	Muğla Sıtkı Koçman Üniversitesi	Bilişim Sistemleri Mühendisliği
2016 - ...	Lisans	Anadolu Üniversitesi	İşletme
2008 - 2012	Lisans	Süleyman Demirel Üniversitesi	Bilgisayar Mühendisliği

(\*) Diploma Türü (Lisans, Y.Lisans, vs.)

## 3. AKADEMİK DENEYİM

Görev Dönemi	Ünvan	Bölüm	Üniversite
2014 - ...	Arş. Gör.	Bilişim Sistemleri Mühendisliği	Muğla Sıtkı Koçman Üniversitesi

#### 4. YAYIN BİLGİLERİ

##### **Ulusal hakemli dergilerde yayımlanmış tam makale**

1. Sağbaşı, E.A, ve Ballı, S. (2016) Akıllı Telefon Algılayıcıları Ve Makine Öğrenmesi Kullanılarak Ulaşım Türü Tespiti, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22(5), 376-383.

##### **Uluslararası kongre, sempozyum, panel, çalıştay gibi bilimsel, sanatsal toplantılarda sözlü olarak sunulan ve tam metin olarak yayımlanan bildiri**

1. Sağbaşı, E.A, ve Ballı, S. (2016) İnsan Aktivitelerinin Bilek Hareketleri Kullanılarak Tahmin Edilmesi, *3. International Management Information Systems Conference*, 6-8 October 2016, İzmir, Turkey, 52-58
2. Sağbaşı, E.A, ve Ballı, S. (2016) Akıllı Telefon Sensör Verileri ile Eylem Tanımda Lojistik Regresyon ve kNN Yöntemlerinin Karşılaştırılması, *1st International Conference on Engineering Technology and Applied Sciences*, 21-22 April 2016, Afyonkarahisar, Turkey, 894-899.
3. Yıldız T., Sağbaşı, E.A, ve Ballı, S. (2016) Veri Madenciliği Yöntemlerinin İnşaat Sektörüne Uygulanması, *1st International Conference on Engineering Technology and Applied Sciences*, 21-22 April 2016, Afyonkarahisar, Turkey, 1342-1346.
4. Sağbaşı E.A, Ballı, S, ve Şen, F. (2016) Sosyal Medya ve Gençler Üzerindeki Etkileri, *Uluslararası Gençlik Araştırmaları Kongresi*, 27-31 May 2016, Marmaris, Turkey, Baskıda.

##### **Ulusal kongre, sempozyum, panel, çalıştay gibi bilimsel, sanatsal toplantılarda sözlü olarak sunulan ve tam metin olarak yayımlanan bildiri**

1. Sağbaşı E.A, ve Ballı, S. (2016) Giyilebilir Akıllı Cihazlar: Dünü, Bugünü ve Geleceği, *Akademik Bilişim Konferansı*, 3-5 Şubat 2016, Aydın, Türkiye, Baskıda.

2. Saębaş E.A, ve Ballı, S. (2015) Akıllı Telefon Sensörlerinin Kullanımı ve Ham Sensör Verilerine Erişim, *Akademik Bilişim Konferansı*, 4-6 Şubat 2015, Eskişehir, Türkiye, 158-164.
3. Saębaş, E.A. (2014) Küresel Konumlama Servisi Kullanarak Araç Takibi ve Mobil Cihazlar Arası Haberleşme, *Akademik Bilişim Konferansı*, 5-7 Şubat 2014, Mersin, Türkiye, 129-132.

**Alanında tanınmış uluslararası yayınevlerince yayımlanan kitaplarda bölüm yazarlığı**

1. Ballı, S., ve Saębaş, E.A. (2016) The Usage of Statistical Learning Methods on Wearable Devices and a Case Study: Activity Recognition on Smartwatches, *Advances in Statistical Methodologies and Their Applications to Real Problems*, InTech, Rijeka, Croatia, Baskıda.

**Bilimsel Araştırma Projelerinde (BAP) görev alma (araştırmacı, eğitmen, danışman, vb. olarak)**

1. Akıllı Saat Teknolojisi ve Makine Öğrenmesi Algoritmaları ile Giyilebilir Cihazlar Üzerinden Eylem Tanıma Uygulaması Geliştirilmesi.