

## Akıllı Saat Algılayıcıları ile İnsan Hareketlerinin Sınıflandırılması

Serkan BALLI<sup>1</sup>, Ensar Arif SAĞBAŞ<sup>\*1</sup>

<sup>1</sup>Muğla Sıtkı Koçman Üniversitesi, Teknoloji Fakültesi, Bilişim Sistemleri Mühendisliği Bölümü, 48000, Muğla

(Alınış / Received: 14.11.2016, Kabul / Accepted: 20.04.2017, Online Yayınlanma / Published Online: 08.05.2017)

### Anahtar Kelimeler

Hareket sınıflandırma,  
Akıllı saat,  
İvmeölçer,  
Adımsayar,  
Makine öğrenmesi

**Özet:** Giyilebilir teknolojideki gelişmelerle birlikte ortaya çıkan cihazlar hızla gündelik hayatın bir parçası haline gelmiştir. Özellikle sahip oldukları algılayıcılar, bu cihazların kullanılabilirliğini artırmaktadır. Bu çalışmanın amacı, akıllı saatlerin sahip olduğu algılayıcılar kullanılarak insan hareketlerinin tespit edilmesidir. Bu amaçla, akıllı saatler üzerinde çalışabilen bir mobil uygulama geliştirilmiştir. Geliştirilen uygulama ile 9 farklı insan hareketi için algılayıcı verileri akıllı saat aracılığı ile toplanmış ve 4 saniyelik pencere aralıkları ile desenler oluşturulmuştur. Oluşturulan desenler 10 farklı makine öğrenmesi yöntemi ile test edilmiş ve performansları karşılaştırılmıştır.

## Classification of Human Motions with Smartwatch Sensors

### Keywords

Motion classification;  
Smartwatch,  
Accelerometer,  
Step counter,  
Machine learning

**Abstract:** The devices generated with the developments in wearable technology are quickly becoming a part of daily life. Especially, sensors they have increase the usefulness of these devices. The aim of this study is detection of human motions by using smartwatch sensors. For this purpose, a mobile application has been developed which runs on smartwatches. Sensor data for 9 different types of human motions have been collected via smartwatches and patterns have been formed with 4 second window intervals. Created patterns have been tested with 10 different machine learning methods and their performances have been compared.

### 1. Giriş

Giyilebilir algılayıcılar, insanların günlük aktivitelerini yerine getirirken üzerlerinde bulunabilen küçük boyutlu cihazlardır. Bu algılayıcılar konum değişimi, hareket yönü veya hareket hızı gibi kişinin fiziksel durumunu kaydetmektedir. İvmeölçer, mikrofon, GPS (Küresel Konumlandırma Sistemi), barometre vb. algılayıcılar bu gruba dâhildir. Bu giyilebilir algılayıcıların birçoğu akıllı telefonlarda ve akıllı saatlerde dâhili olarak bulunmaktadır [1].

Aktivite tespiti uygulamaları, sağlıklı yaşam konusunda 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 akıllı telefon, sağlıklı bir spor alışkanlığı oluşturmak amacıyla kullanıcıya uzun süre hareketsiz kaldığı durumlarda bir hatırlatma gönderebilir. Bu tip uygulamalar insanların ne kadar yürüdükleri, kaç

basamak çıktıkları, ne kadar süre uydukları, kaç kalori yaktıkları gibi bilgileri takip edebilmektedir [2].

Literatür incelendiğinde insan hareketlerinin sınıflandırılmasında çeşitli makine öğrenmesi yöntemlerinin ve farklı tarzda algılayıcı cihazların kullanıldığı görülmektedir. Khan ve ark. [3], insan bedenine yerleştirilen ivmeölçer ile uzanma, ayakta durma, koşma ve yürüme eylemlerinin tespit edilmesini sağlamıştır. Yapılan testler sonucu dört aktivitenin tahmininde %99'un üzerinde doğruluk elde edilmiştir. Yang ve ark. [4], ivme verileri ile aktivite tespiti gerçekleştirmiştir. Testler sonucunda geliştirilen sistemin yürüme, koşma, ayakta durma, bilgisayarda çalışma, ovma, oturma, temizlik yapma ve dış fırçalama eylemlerinin sınıflandırılmasında %90'ın üzerinde başarı oranına sahip olduğu görülmüştür. Riboni ve Bettini [5], dış 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 verilerini kullanmıştır. Sağbaş ve Ballı [6] akıllı telefonların

ivmeölçer, GPS ve jiroskop algılayıcılarından elde ettikleri veriler ile yürüme, koşma, merdiven inme ve çıkma, asansör kullanma, bisiklet sürme ve sabit pozisyonda bulunma eylemlerini makine öğrenmesi yöntemi kullanarak sınıflandırmıştır. Chernbumroong ve ark. [7] ivmeölçer algılayıcısına sahip saat ile aktivite sınıflandırması gerçekleştirmiştir. Kwapisz ve ark. [8], akıllı telefonlar ile topladığı yürüme, hafif tempoda koşma, merdiven çıkma ve inme, oturma ve ayakta durma eylemlerini %91,7 oranında doğru sınıflandırmıştır. Lara ve ark. [9] tarafından yapılan çalışmada, kullanıcı göğüs kafesi üzerinde bulunan algılayıcı verileri ile yürüme, koşma, oturma, yukarı çıkma ve aşağı inme eylemlerinin tanınması gerçekleştirilmiştir. da Silva ve Galeazzo [10], saatten elde edilen ivme verileri ile kullanıcının gerçekleştirdiği 8 farklı eylemi sınıflandırmıştır. Dadashi ve ark. [11], yüzücülerin koluna ve bacağına yerleştirdiği ivmeölçer ve jiroskop algılayıcıları ile kurbağalama yüzme aşamalarının otomatik tespit edilmesini sağlayacak bir Saklı Markov Modeli önermiştir. Mortazavi ve ark. [12], tarafından Samsung Galaxy Gear akıllı saat ile beş farklı jimnastik hareketinin algılanmasında ivmeölçer algılayıcı ile jiroskop ve ivmeölçer algılayıcısı kombinasyonunun performans farklarının değerlendirilmesi yapılmıştır. Sınıflandırma yöntemi olarak Rasgele Orman, Karar Ağaçları, Destek Vektör Makineleri ve Naive Bayes yöntemleri karşılaştırılmıştır. Dong ve ark. [13], kullanıcının bileğine yerleştirdikleri akıllı telefon ile yemek yeme döngülerini tespit etmiştir. Çalışmada, akıllı telefonun ivmeölçer ve jiroskop algılayıcı verileri kullanılmıştır. Guiry ve ark. [14] akıllı saat ve akıllı telefonların günlük aktivitelerin tespit edilmesindeki rolünü araştırmıştır. 9 farklı eylemi tespit etmek için 5 farklı makine öğrenmesi yöntemi ile testler gerçekleştirilmiştir. Wang ve ark. [15], akıllı saat kullanan bir kullanıcının dizüstü bilgisayar klavyesi kullanım bilgilerini elde etmeyi amaçlamıştır. Tuşa 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 ve ark. [16], tarafından yapılan çalışmada akıllı saat ve akıllı telefon algılayıcı verileri ile insan hareketlerini tespit edilmiştir. 6 farklı eylemin tespit edildiği çalışmada, sigara içme, yemek yemeyi unutma ve çok fazla kahve içme gibi kötü alışkanlıkların tespit edilip, önüne geçilmesi amaçlanmıştır. Weiss ve ark. [17] tarafından yapılan çalışmada akıllı saat ve akıllı telefon ile gerçekleştirilen eylem tanınmanın performansı karşılaştırılmıştır. Bilek hareketlere bağlı eylemlerim akıllı saatler ile daha başarılı sınıflandırıldığı sonucuna varılmıştır. Ballı ve Sağbaş [18] 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 dış fırçalama) sınıflandırılmıştır. En başarılı sonuç Bayes Ağları yönteminden elde edilmiştir.

Verilen literatüre bakıldığında insan hareketlerinin sınıflandırılmasında vücuda yerleştirilen algılayıcılar ve akıllı telefonların yaygınlaşması sonrasında akıllı telefonların kullanıldığı görülmektedir. Akıllı saat kullanımı ise akıllı telefon kullanımına nazaran daha kısıtlı durumdadır. Bu çalışmada geçmiş çalışmalardan farklı olarak algılayıcı verilerinin elde edilebilmesi ve anlık olarak sınıflandırmanın gerçekleştirilebilmesi için vücuda yerleştirilen algılayıcılar yerine akıllı saatler kullanılmıştır. Aktivitenin tespit ve takip edilebilmesi için sadece saat yeterli olacak şekilde tasarlanmıştır. Bu amaçla kişi kol hareketleri ile ayırt edilebilecek yürüme, yazı yazma, klavye kullanma, koşma, tahtaya yazı yazma, temizlik yapma, ayakta durma, sabit pozisyonda durma ve dış fırçalama eylemlerinden oluşan bir veri seti oluşturulmuş ve etiketlenmiştir. Ek olarak, elde edilen veriler 10 farklı makine öğrenmesi yöntemi (Naive Bayes, Lojistik Regresyon, kNN, Rastgele Orman, Bayes Ağları, Model Ağaçları, Çok Katmanlı Algılayıcı, C4.5, Karar Tablosu, Rastgele Ağaç) ile sınıflandırılmış ve sonuçları karşılaştırılmıştır. Diğer çalışmalardan farklı olarak ivmeölçer algılayıcısına ek olarak Android Wear işletim sisteminin desteklediği adımsayar algılayıcısı verileri de veri setine dâhil edilmiştir.

Çalışmanın ikinci kısmında kullanılan makine öğrenmesi yöntemleri kısaca açıklanacaktır. Üçüncü kısımda, akıllı saat ile veri setinin oluşturulması ve aktivite tespitinin gerçekleştirilmesi anlatılacaktır. Dördüncü kısımda gerçekleştirilen deneysel çalışmalar açıklanacak ve beşinci bölümde çıkarılan sonuçlara ve gelecek çalışmalara değinilecektir.

## 2. Kullanılan Makine Öğrenmesi Yöntemleri

Akıllı telefonlar ya da insan vücuduna yerleştirilen algılayıcılar yardımı ile gerçekleştirilen insan hareketlerinin sınıflandırılması uygulamalarında makine öğrenmesi sınıflandırma yöntemlerinden faydalanılmaktadır. Bu çalışmada kullanılan makine öğrenmesi yöntemleri alt başlıklarda anlatılacaktır.

### 2.1. Naive Bayes (NB)

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. Test verisine göre sınıfı tahmin etmek için denklem 1'de verilen Bayes Teoremi kullanılır [19].

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

## 2.2. Lojistik regresyon (LR)

Lojistik regresyon bir veya çok ön göstergeli değişkene bağlı kategorik bağımlı değişkenlerin sonuçlarını tahmin etmede kullanılan bir tür regresyon analizidir. Geçmişte, temel lojistik regresyon modelinin genişletilmiş hali olarak farklı türde modeller geliştirilmiştir. Çok terimli lojistik regresyon modeli ikiden fazla ayrı sonuca izin veren lojistik regresyonu genelleştiren bir modeldir. Yani bağımsız değişkenleri verilen, kategorik dağıtılan bağımlı değişkenlerin farklı olası sonuçlarını tahmin etmek için kullanılan modeldir [20].

## 2.3. k En yakın komşu (kNN)

K En Yakın Komşu algoritması teorik ve basit sınıflandırma yöntemlerinden biridir. Bu algoritmada sınıflandırılacak olan yeni örneğe veri setinden en yakın mesafedeki k tane örneğe bakılır. Bu k örnek hangi sınıfa daha fazla dâhil ise yeni örnek de o sınıfa dâhil edilir [21]. Yapılan çalışmada k değeri 3 olarak alınmıştır. Mesafe hesabı için ise denklem 2'de formülü verilen Öklid uzaklık ölçütü kullanılmıştır.

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

## 2.4. Rasgele orman (RO)

Tek bir ağaç yapısı yerine, çok sayıda ağaç yapısının kullanılması, yani bir ormanın sınıflandırma amacıyla kullanılabilmesi fikri Breiman [22] tarafından sunularak yöntemin esasları belirlenmiştir [23].

Rastgele orman yönteminde, veri kümesinden Bootstrap yöntemi ile örnekler seçilmekte ve bu örneklerle 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. [23].

## 2.5. Bayes ağları (BA)

Bayes ağları düğümlerin değişkenleri, okların bu düğümler arasında bağlantıyı temsil ettiği belirsizlik altında karar vermek için kullanılan grafiksel modellerdir. Bir Bayes ağında düğümler çevreden elde edilen rasgele değişkenleri temsil eder ve yönlü oklar ile birbirine bağlanır. Bu oklar düğümler arasındaki bağımlılığı temsil eder. Ayrık iki düğüm arasında bağlantının gücü, o iki düğüm arasındaki koşullu olasılık ile ölçülür. İlk olarak değişkenler arasındaki ilgi belirlenir. Bunun sonucunda düğümlerin neleri temsil ettiği ve hangi değerleri aldığı saptanır. Ayrık değerlere sahip düğümler ele alındığında, değerler hem birbirini dışlayan hem de kapsamlı olmalıdır. Bu da, bu değerlerin tam değerler almasıdır. Ağın yapısı veya topolojisi değişkenler arasındaki nitel ilişkiyi ele alır. Özellikle, iki düğüm

birbirini etkiliyor veya birinin gerçekleşmesine neden oluyorsa bu iki düğüm direk bağlantılı olarak gösterilir [24].

## 2.6. Model ağaçları (MA)

Çoğu makine öğrenmesi yöntemi pratikte sürekli sayısal değerler alan bir "sınıf" tahmini barındırmaktadır. Bu tür sorunları ele almada model ağaçları yöntemi başarılı sonuçlar göstermektedir. Yapısal olarak model ağacı, yapraklarında terminal sınıf değerleri yerine doğrusal regresyon kullanan karar ağacı yapısı kullanılmaktadır. Sayısal değerli öznitelikler bu yapıda doğal bir rol oynamaktadır, ayrık öznitelikler ise daha az doğal ele alınabilmektedir. Bu, ayrık özniteliklerin doğal bir rol oynadığı klasik karar ağacının tersi bir durumdur [25].

## 2.7. Çok katmanlı algılayıcı (ÇKA)

Çok katmanlı algılayıcı, giriş verilerinin bir uygun çıkış dizisi üzerinde ayarlandığı ileri beslemeli bir yapay sinir ağı modelidir. Çok katmanlı algılayıcı bir yönlendirilmiş grafikte her katmanın tamamen sonraki birine bağlı olduğu düğümlerin birden çok katmanını içermektedir. Giriş düğümleri haricinde, her bir düğüm doğrusal olmayan bir işleve sahip nörondur. Çok katmanlı algılayıcı ağı eğitimi için geri yayılım olarak adlandırılan denetimli öğrenme tekniğini kullanır [20].

## 2.8. C4.5

C4.5 algoritması bilgi entropi kavramı kullanarak bir eğitim setinden karar ağacı inşa eder. Eğitim seti  $S = S_1, S_2, \dots, S_n$  verilerinin sınıflandırılmış örnekleridir. Her bir  $S_i$  örneği p boyutlu vektörden  $(X_{1,i}, X_{2,i}, \dots, X_{p,i})$  oluşmaktadır. Burada  $X_j$  örneklerin niteliklerini veya özelliklerini göstermektedir. Ağacın her bir düğümünde, C4.5 alt kümelerdeki zenginleştirilmiş verinin niteliğini seçer. Bölünme ölçütü normalize bilgi kazancıdır. En yüksek normalize bilgi kazancına sahip nitelik karar için seçilir. Sonrasında C4.5 algoritması daha küçük alt listelerden çekilir [20].

## 2.9. Karar tablosu (KT)

Bir karar tablosu ilgili bir dizi kararın alınacağı eylemi gösteren iki boyutlu bir tablodur. Genel olarak bir karar tablosu, satır ve sütunlardan oluşan bir matris olarak sunulmaktadır. Her sütun satırların koşullarını ve işlemlerin kurallarını tanımladığı tek bir kurala karşılık gelmektedir. En iyi birleşimleri arama açısından, farklı algoritmalar uygulanmaktadır [20].

## 2.10. Rasgele ağaç (RA)

Rasgele ağaç, her düğümünde k rasgele öznitelige sahip bir mümkün ağaç kümesi ile rasgele çizilen bir ağaçtır. Bu bağlamda, rasgele olması; ağaçlar kümesi

içindeki her ağacın eşit örneklenme şansının olmasıdır. Başka bir deyişle ağaçlar "uniform" dağılıma sahiptir. Büyük rasgele ağaç kümeleri genelde doğru modellere öncülük eder ve verimli bir biçimde rasgele ağaçlar oluşturulabilir [26].

### 3. Geliştirilen Uygulama

Bu çalışmada akıllı saat algılayıcı verileri ve makine öğrenmesi yöntemleri kullanılarak insan hareketlerinin tespit edilmesi gerçekleştirilmiştir. Makine öğrenmesi için veri setinin hazırlanması ve çevrimiçi eylem tanımayı gerçekleştirmek için Şekil 1'de görseli verilen Moto 360 [27] marka akıllı saat kullanılmıştır. Bu saat Android Wear işletim sistemine sahiptir ve akıllı telefonlar ile senkronize çalışabilmektedir. İvmeölçer, manyetometre, jiroskop, adımsayar, nabız ve ortam ışığı algılayıcılarına sahip olan bu cihaz saniyede 100 örnek algılayıcı bilgisi sağlayabilmektedir. Çalışma süresince veri setini oluşturmak için ve eylem tanımayı gerçekleştirmek için iki farklı mobil uygulama geliştirilmiştir. Bu bölümün devamında geliştirilen mobil uygulamalar ve hareket sınıflandırma aşamasındaki parametre seçimi anlatılmaktadır.



Şekil 1. Çalışmada kullanılan akıllı saat

Çalışmada kullanılacak veri setini oluşturmak 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 2'de gösterilen arayüzü algılayıcı verilerini toplamayı başlatacak ya da sonlandıracak bir butona sahiptir.



Şekil 2. Akıllı saat veri seti uygulaması ekran görüntüleri

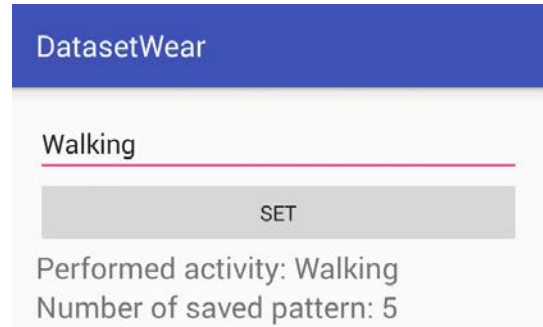
Toplanan algılayıcı bilgileri bağlı bulunan akıllı telefona aktarılmakta ve telefonun dâhili hafızasına

istenilen isim ile CSV formatında kaydedilmektedir. Algılayıcı verilerinin akıllı telefonların dâhili hafızasında depolanmasını gösteren yapı Şekil 3'de gösterilmektedir.



Şekil 3. Veri seti uygulaması yapısı

Kişinin gerçekleştirdiği eylemin etiketlenme kısmı akıllı telefon tarafında gerçekleştirilmektedir. Telefon için geliştirilen uygulamanın ekran görüntüsü Şekil 4'de gösterilmektedir.



Şekil 4. Veri seti uygulaması akıllı telefon ekran görüntüsü

Akıllı saat için geliştirilen uygulama, saniyede 50 örnek toplayacak şekilde ayarlanmıştır. Bu sıklıkla toplanan örnekler en hızlı insan aktivitesinin tespit edilebilmesi için yeterlidir [28]. Uygulamanın belli aralıklarla topladığı örneklerin eşleştiği akıllı telefona aktarılması sağlanmıştır. Toplanan bütün veriler bilgisayar ortamında birleştirilerek her sınıf için ayrı ayrı 100.000 örnek elde edilmiştir. Bu örnekler 4 saniyelik pencereye bölünmüş ve her sınıf için 500 desen elde edilmiştir. 4 saniyelik pencereler ile eylem geçişleri arasında hatalı hesaplamalar en aza indirilmesi amaçlanmıştır. Çalışmada tahtaya yazı yazma, yürüme, hafif tempoda koşma, diş fırçalama, kâğıda yazı yazma, klavye kullanma, ayakta durma, temizlik yapma ve sabit pozisyonda bekleme eylemleri için veriler toplanmıştır. Yürüme eylemi birey elleri cebinde, eşya taşır durumda ve ellerini sallayarak yürüme olacak şekilde çeşitlendirilmiştir. Temizlik yapma ise elektrikli süpürge kullanma ve toz alma eylemlerini içermektedir. Bütün eylemlerin verileri toplanırken akıllı saat bireyin, yazı yazarken kullandığı elinin bileğinde konumlandırılmıştır.

İnsan hareketlerinin çevrimiçi sınıflandırılmasının gerçekleştirilebilmesi için akıllı saatler üzerinde çalışabilen bir mobil uygulama geliştirilmiştir. Bu

uygulama aynı saat ile öncesinde verileri toplanan veri setini ve dördüncü bölümde anlatılan deneyler sonucunda en iyi sonucu veren makine öğrenmesi yöntemini 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 4 saniyede bir topladığı algılayıcı verilerini desene çevirmekte, Weka API [29] kullanarak sınıflandırma işlemi gerçekleştirilmekte 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 5’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 5. 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 6’da gösterilmektedir.



Şekil 6. Tespit edilen hareketleri akıllı telefonda raporlayan uygulama ekran görüntüsü

#### 4. Deneysel Çalışma ve Tartışma

Çalışmada Android Wear işletim sistemine sahip akıllı saatlerden elde edilen algılayıcı verilerinin makine öğrenmesi ile işlenerek insan hareketlerinin tespit edilmesi gerçekleştirilmiştir. İvmeölçer ve adımsayar algılayıcısından elde edilen veriler Rastgele Orman, Naive Bayes, kNN, C4.5, Bayes Ağları, Çok Katmanlı Algılayıcı, Rastgele Ağaç, Lojistik Regresyon, Karar Tablosu ve Model Ağaçları olmak

üzere 10 farklı makine öğrenmesi yöntemi ile test edilmiş ve sonuçları karşılaştırılmıştır.

İvmeölçer algılayıcısı Şekil 7’de gösterilen eksenler doğrultusunda akıllı saate etki eden ivmeyi ölçmektedir. Ham ivmeölçer algılayıcı bilgisi Android Wear işletim sisteminde üç eksende  $m/sn^2$  cinsinden elde edilir. Ham ivmeölçer algılayıcısı verisi  $Acc_i = \langle x_i, y_i, z_i \rangle$ ,  $i = (1, 2, 3, \dots)$  vektörlerini içerir. İvmelenme değerlerinin yanında ayrıca zaman bilgisi de elde edilir. Mevcut çoğu ivmeölçer kullanıcı arayüzünde örnekleme hızını ayarlamaya imkân sunmaktadır. [2,30].




Şekil 7. Tespit edilen hareketleri akıllı telefonda raporlayan uygulama ekran görüntüsü

Adımsayar algılayıcısı, algılayıcı aktif olduğu sürece kullanıcının cihazı açtığı andan itibaren attığı adım sayısını sağlamaktadır. Adımsayar, adım tespit edici algılayıcıya göre daha gecikmeli fakat daha güvenilir olarak çalışmaktadır. Çalışmada oluşturulan desenlerde elde edilen son değerden ilk değer çıkarılarak mevcut desen için adımsayar algılayıcısından elde edilen adım sayısı kullanılmıştır [31]. Oluşturulan veri setinde eylemlere ait ortalama adım sayıları Tablo 1’de verilmiştir.

Tablo 1. Eylemlere ait ortalama adım sayısı

Eylem	Ortalama Adım Sayısı
Ayakta durma	0
Yürüme	7.194
Diş fırçalama	0
Koşma	10.99
Klavye kullanma	0
Temizlik yapma	2.216
Tahtaya yazı yazma	0
Sabit	0
Yazı yazma	0

İvmeölçer algılayıcısından elde edilen verilerin ortalaması akıllı saatin ne pozisyonda durduğu hakkında bilgi vermektedir. Şekil 8’de masa üzerinde sabit olarak bulunan akıllı saatin ivmeölçer algılayıcısından elde edilen sonuç gösterilmiştir.




Şekil 8. Masa üzerinde konumlandırılmış akıllı saat ivmeölçer algılayıcısı örnek verileri

Cihazın konumunda yapmış olduğu değişiklikler ise aynı verilerin standart sapma değerleri ile elde edilmektedir. Çalışmada her 4 saniyede atılan adım sayısı ile ivmeölçer algılayıcısının 3 ekseninden elde edilen ham verilerin standart sapması ve ortalama değerleri oluşturulan desenlerde parametre olarak kullanılmıştır. Saatlerin kullanıcının kolunda yer alması, konumlandırma çeşitliliğe sahip olmamasından dolayı ivmeölçer algılayıcısından elde edilen veriler direkt olarak desende parametre olarak kullanılmıştır.


Sırasıyla yürüme, koşma, tahtaya yazı yazma, klavye kullanma, yazı yazma, diş fırçalama, temizlik yapma, sabit durma ve ayakta durma eylemlerine ait örnek ivmeölçer algılayıcısı verileri 4 saniyelik pencerelerde (200 veri)  $m/sn^2$  biriminde şekil 9-17'de gösterilmektedir.

Veri setinin eğitim ve test verisi olarak nasıl ayrılması gerektiği veri setinin büyüklüğü ile ilgili bir durumdur. Genelde veri setinin büyüklüğüne göre oran olarak 80:20, 70:30, 60:40 veya 50:50 gibi parçalanabilir. Bu tür sınıflandırma problemlerinde en az eğitim verisiyle modeli eğiterek büyük oranda test verisi üzerinde denenmesi sonucunda yüksek doğruluk oranlarının yakalanması hedeflenir. Bu aynı zamanda kullanılan yöntemin tutarlı olduğunu da gösterir. Bu yüzden çalışmada 80:20, 70:30, 60:40, 50:50 ve bu değerlerin arasında farklı oranlar denenmiş ve en iyi oran 56:44 olarak bulunmuştur. 56:44 diğer oranlarla aynı başarıyı sağladığı için veri bu oranlar kullanılarak ayrılmıştır. Çapraz doğrulama (Cross Validation) yöntemi ise eğitim ve test verilerinin kısıtlı olduğu durumlarda kullanılan bir yöntemdir. Bu yöntemde eğitim verileri aynı zamanda test verileri olarak da kullanılır. Bu durum yüksek doğruluk oranları verse de farklı ve yeni bir test verisinde üzerinde denendiğinde çok kötü sonuçlar da elde edilebilmektedir. Bu yüzden çok tercih edilen bir yöntem değildir. Veri elde etmenin maliyetli olduğu problemlerde ve az sayıda veriden oluşan veri setlerinde kullanılır [32, 33]. Çalışmada geçen problem için yeterli sayıda (4500 adet) veri üzerinde çalışıldığı için çapraz doğrulama yöntemi tercih edilmemiştir.


Testler 10 farklı makine öğrenmesi yöntemi kullanılarak ivmeölçer algılayıcı verileri ve ivmeölçer algılayıcı ile adımsayar algılayıcısı verilerinin birleşimi ile gerçekleştirilmiş ve performansları karşılaştırılmıştır. Sınıflandırma işlemlerinde Weka Toolkit versiyon 3.8 [34] kullanılmıştır. Yöntemlere göre elde edilen doğruluk oranları ve Ortalama Karesel Hatanın Karekökü (Root Mean Squared Error, RMSE) değerleri Tablo 2'de gösterilmektedir. Yapılan deneyler sonucunda en iyi sonuç Rastgele Orman yöntemi ile ivmeölçer ve adımsayar algılayıcısı verilerinin birleşiminden elde edilmiştir.




Şekil 9. Yürüme eylemine ait ivmeölçer verileri




Şekil 10. Koşma eylemine ait ivmeölçer verileri




Şekil 11. Tahtaya yazı yazma eylemine ait ivmeölçer verileri




Şekil 12. Klavye kullanma eylemine ait ivmeölçer verileri




Şekil 13. Yazı yazma eylemine ait ivmeölçer verileri




Şekil 17. Ayakta durma eylemine ait ivmeölçer verileri



Şekil 14. Dış fırçalama eylemine ait ivmeölçer verileri



Şekil 15. Temizlik yapma eylemine ait ivmeölçer verileri



Şekil 16. Sabit durma eylemine ait ivmeölçer verileri

Tablo 2. Yöntemlere göre elde edilen doğruluk oranları ve ortalama karesel hatalar

Yöntem	İvmeölçer		İvmeölçer + Adımsayar	
	%	RMSE	%	RMSE
<b>C4.5</b>	92.90	0.1225	93.35	0.1175
<b>RO</b>	95.75	0.0882	96.15	0.0851
<b>RA</b>	92.50	0.1291	93.60	0.1193
<b>KT</b>	85.15	0.1753	85.60	0.1716
<b>MA</b>	94.35	0.1037	94.75	0.1010
<b>kNN</b>	88.75	0.1374	88.75	0.1373
<b>LR</b>	85.70	0.1492	87.90	0.1413
<b>ÇKA</b>	80.05	0.1825	80.30	0.1870
<b>NB</b>	76.35	0.2057	73.05	0.2196
<b>BA</b>	91.70	0.1208	92.75	0.1128

Algılayıcı kombinasyonlarının performansları değerlendirildiğinde adımsayar algılayıcısının ivmeölçer algılayıcısı verilerini zenginleştirdiği görülmektedir. Naive Bayes, kNN, Karar Tablosu, Lojistik Regresyon ve Çok Katmanlı Algılayıcı yöntemlerinden elde edilen doğruluk oranları %90'ın altında kaldığı gözlemlenmektedir. Ortalama karesel hatalarda ise en yüksek doğruluk oranına sahip Rastgele Orman yönteminin en düşük değere (0.0851) sahip olduğu görülmektedir. Yöntemlere göre elde edilen duyarlılık-DY (Sensitivity) ve eğri altında kalan alan (Area Under Curve, AUC) değerleri Tablo 3'de verilmiştir.

Yöntemlere göre duyarlılık ve eğri altında kalan alan değerleri incelendiğinde elde edilen sonuçların doğruluk oranları ile benzerlik gösterdiği sonucuna varılmaktadır. En yüksek doğruluk oranına sahip Rastgele Orman yöntemi en yüksek duyarlılık ve eğri altında kalan alan değerine sahiptir. En küçük değerler ise en düşük doğruluk oranına sahip Naive Bayes yöntemine aittir.

Daha iyi sonuç veren ivmeölçer ve adımsayar algılayıcısının birlikte kullanıldığı yöntemlere göre elde edilen karmaşıklık matrisleri Tablo 4-13'de gösterilmektedir. Karmaşıklık matrislerinde A; ayakta durma eylemini, B; dış fırçalama eylemini, C; klavye ile yazı yazma eylemini, D; koşma eylemini, E; sabit pozisyonda durma eylemini, F; tahtaya yazı yazma eylemini, G; temizlik yapma eylemini, H; yazı yazma eylemini, I ise yürüme eylemini göstermektedir.

**Tablo 3.** Yöntemlere göre elde edilen duyarlılık ve eğri altında kalan alan değerleri

Yöntem	İvmeölçer		İvmeölçer + Adımsayar	
	DY	AUC	DY	AUC
C4.5	0.929	0.972	0.934	0.970
RO	0.952	0.998	0.961	0.997
RA	0.925	0.958	0.936	0.964
KT	0.852	0.974	0.856	0.977
MA	0.944	0.993	0.948	0.993
kNN	0.888	0.971	0.888	0.971
LR	0.857	0.983	0.879	0.986
ÇKA	0.801	0.959	0.795	0.970
NB	0.764	0.968	0.731	0.968
BA	0.917	0.993	0.928	0.994

**Tablo 4.** Bayes Ağları yönteminden elde edilen karmaşıklık matrisi

BA	A	B	C	D	E	F	G	H	I
A	219	1	0	0	0	8	2	0	0
B	0	194	0	0	0	18	17	0	0
C	0	0	224	0	1	0	0	0	0
D	0	0	0	229	0	0	0	0	0
E	0	1	11	0	195	0	0	3	0
F	0	23	0	0	0	190	10	1	0
G	1	18	0	3	0	8	191	0	2
H	0	7	0	0	1	0	2	220	0
I	0	0	0	0	0	0	7	0	193

**Tablo 5.** Naive Bayes yönteminden elde edilen karmaşıklık matrisi

NB	A	B	C	D	E	F	G	H	I
A	221	0	0	0	0	1	1	0	7
B	0	81	1	1	1	126	10	1	8
C	0	0	71	0	150	1	3	0	0
D	0	0	0	226	0	0	3	0	0
E	0	0	2	5	199	0	1	3	0
F	24	4	0	0	3	174	7	0	12
G	4	16	0	5	0	7	83	0	108
H	0	0	0	0	7	0	11	212	0
I	0	0	0	0	0	0	6	0	194

**Tablo 6.** Lojistik Regresyon yönteminden elde edilen karmaşıklık matrisi

LR	A	B	C	D	E	F	G	H	I
A	223	0	0	0	0	2	2	0	3
B	0	160	1	0	0	43	22	1	2
C	0	0	217	0	8	0	0	0	0
D	0	0	0	229	0	0	0	0	0
E	2	0	12	0	188	0	0	8	0
F	2	23	0	0	0	186	11	0	2
G	3	25	3	1	0	3	135	1	52
H	0	3	0	1	1	0	0	225	0
I	0	0	0	0	0	0	5	0	195

**Tablo 7.** Çok Katmanlı Algılayıcı yönteminden elde edilen karmaşıklık matrisi

ÇKA	A	B	C	D	E	F	G	H	I
A	180	0	0	0	0	0	19	0	31
B	0	188	13	1	1	4	20	1	1
C	0	0	225	0	0	0	0	0	0
D	0	0	0	229	0	0	0	0	0
E	0	0	105	1	89	0	0	15	0
F	0	22	2	0	2	148	46	0	4
G	0	33	10	9	0	0	157	4	10
H	0	0	0	5	1	0	0	224	0
I	0	2	0	0	0	0	31	0	166

Bayes ağları yöntemiyle yapılan testte dış fırçalama ve tahtaya yazı yazma eylemlerinin birbiri ile karıştırıldığı görülmektedir (Bkz. Tablo 4). Bununla birlikte temizlik yapma eylemi de doğruluk oranını

düşüren eylemler arasında bulunmaktadır. Tablo 5'de karmaşıklık matrisi verilen Naive Bayes yönteminden elde edilen sonuçlar incelendiğinde büyük oranda yanlış tespitler ile karşılaşmıştır. Dış fırçalama eylemi %55 oranında tahtaya yazı yazma olarak, klavye ile yazı yazma eylemi yaklaşık %67 oranında sabit durma olarak, temizlik yapma eylemi ise %48 oranında yürüme olarak tespit edilmiştir. Bu oranda hatalı tespitler Naive Bayes yönteminin ortalama doğruluğunu %73 değerine düşürmüştür.

Lojistik regresyon yönteminden elde edilen Tablo 6 incelendiğinde, tahtaya yazı yazma, temizlik yapma ve dış fırçalama eylemlerinin doğruluk oranlarında azalmanın gerçekleştiği görülmektedir.

Ortalamada %80.3 doğruluk oranına sahip olan, Tablo 7'de karmaşıklık matrisi verilen Çok Katmanlı Algılayıcı yöntemi klavye ile yazı yazma ve koşma eylemlerini %100 doğruluk ile tespit etmiştir. Fakat bu başarı diğer eylemlerde yakalanamamıştır. Sabit durma eylemi test verilerinin yarısı klavye ile yazı yazma olarak sınıflandırılmıştır.

Karmaşıklık matrisi Tablo 8'de verilen eğitim aşaması olmayan kNN yönteminde ise dış fırçalama, tahtaya yazı yazma, ayakta durma ve temizlik yapma eylemlerinde diğer sınıflara göre daha hatalı sınıflandırmaların gerçekleştirildiği görülmektedir. Bu durum kNN'nin ortalama doğruluğunu %88 değerlerine çekmektedir.

Model Ağaçları, bu çalışmada en başarılı sonuçları veren yöntemler arasında yer almaktadır. Tablo 9'da sonucu verilen bu yöntem ile yapılan testlerde en hatalı sınıflandırmaların dış fırçalama sınıfında yer aldığı görülmektedir. Bunun dışındaki diğer sınıflarda ortalama doğruluk %90'ın üzerinde seyretmektedir.

**Tablo 8.** kNN yönteminden elde edilen karmaşıklık matrisi

kNN	A	B	C	D	E	F	G	H	I
A	214	0	0	0	0	4	10	20	2
B	0	174	3	1	3	32	15	1	0
C	0	1	210	0	14	0	0	0	0
D	0	0	0	227	1	0	0	1	0
E	1	0	8	2	198	0	0	1	0
F	4	39	0	0	1	172	7	0	1
G	11	32	1	5	3	10	158	0	3
H	1	0	0	0	3	0	0	226	0
I	2	2	0	0	0	0	0	0	196

**Tablo 9.** Model Ağaçları yönteminden elde edilen karmaşıklık matrisi

MA	A	B	C	D	E	F	G	H	I
A	224	0	0	0	0	4	0	0	2
B	0	193	3	0	1	14	17	1	0
C	0	1	223	0	0	1	0	0	0
D	0	0	0	229	0	0	0	0	0
E	1	1	13	0	193	0	0	2	0
F	5	5	1	0	0	203	9	0	1
G	2	8	2	0	0	2	207	1	1
H	0	0	0	0	2	0	0	228	0
I	0	0	0	0	0	0	5	0	195



**Tablo 10.** Karar Tablosu yönteminden elde edilen karmaşıklık matrisi

KT	A	B	C	D	E	F	G	H	I
A	216	0	0	0	0	6	6	0	2
B	5	184	1	0	0	21	12	3	3
C	7	0	215	0	0	3	0	0	0
D	7	0	0	218	0	0	0	0	4
E	14	0	12	0	175	1	0	3	5
F	1	26	0	1	2	157	16	18	3
G	23	15	0	0	0	6	150	0	29
H	7	4	0	0	1	7	0	210	1
I	10	0	0	0	0	1	2	0	187

**Tablo 11.** C4.5 yönteminden elde edilen karmaşıklık matrisi

C4.5	A	B	C	D	E	F	G	H	I
A	221	0	0	0	0	9	0	0	0
B	0	187	4	0	1	18	17	0	2
C	0	0	218	0	6	0	1	0	0
D	0	0	0	227	0	0	2	0	0
E	0	0	10	0	194	0	1	5	0
F	3	12	1	0	0	203	5	0	0
G	3	17	0	0	0	8	194	0	1
H	0	2	0	0	1	0	0	227	0
I	0	0	0	0	0	0	4	0	196

**Tablo 12.** Rasgele Orman yönteminden elde edilen karmaşıklık matrisi

RO	A	B	C	D	E	F	G	H	I
A	225	1	0	0	0	3	1	0	0
B	0	202	0	0	3	12	10	2	0
C	0	0	223	0	2	0	0	0	0
D	0	0	0	229	0	0	0	0	0
E	0	0	11	0	195	0	1	3	0
F	0	5	0	0	0	213	6	0	0
G	2	7	0	0	0	0	213	0	1
H	0	0	0	0	1	0	0	229	0
I	0	0	0	0	0	0	5	0	195

**Tablo 13.** Rasgele Ağaç yönteminden elde edilen karmaşıklık matrisi

RA	A	B	C	D	E	F	G	H	I
A	223	2	0	0	0	5	0	0	0
B	1	192	0	0	3	19	13	1	0
C	0	1	222	0	2	0	0	0	0
D	0	0	0	228	0	0	1	0	0
E	0	0	11	0	194	0	2	3	0
F	2	11	1	0	0	202	8	0	0
G	6	13	1	1	0	5	191	0	6
H	0	1	0	0	3	1	0	225	0
I	0	0	2	0	0	0	3	0	195

Tablo 10 incelendiğinde tahtaya yazı yazma %30, temizlik yapma %33, sabit durma %16, dış fırçalama ise %20 hatalı sınıflandırıldığı görülmektedir. Diğer sınıflar %90'ın üzerinde değerlerle doğru sınıflandırılmıştır.

Ortalama doğru sınıflandırma oranı %93'ün üzerinde olan C4.5 yönteminde ise en hatalı sınıflandırmalar diğer yöntemlere benzer olarak dış fırçalama, temizlik yapma ve tahtaya yazı yazma eylemlerinde yer almaktadır (Bkz. Tablo 11).

Tablo 12'de çalışmanın en başarılı sonucu veren Rasgele Orman yönteminin karmaşıklık matrisi bulunmaktadır. Bu yöntemde tahtaya yazı yazma ve temizlik yapma eylemlerinde karşılaşılan hatalı sınıflandırmaların azaldığı görülmektedir. Fakat sabit durma eyleminin klavyede yazı yazma eylemi ile

karışması ve dış fırçalama eylemindeki hatalar ortalama doğruluk oranını %96'lara düşürmektedir.

Tablo 13'de gösterilen Rasgele Ağaç yönteminden elde edilen sonuçlar C4.5 yönteminden elde edilenlere benzerlik göstermektedir. Rasgele Ağaç yöntemiyle ortalama %94'e yakın doğruluk oranı yakalanmıştır.

Test edilen on farklı makine öğrenmesi sonucunda Naive Bayes ve Yapay Sinir Ağları yöntemleri dışında %85'in üzerinde doğruluk oranları yakalanmıştır. Tüm yöntemlerde ortak olarak en hatalı sınıflandırmalara dış fırçalama, tahtaya yazı yazma ve temizlik yapma eylemlerinde rastlanmıştır.

## 5. Sonuç

Bu çalışmada Android Wear işletim sistemine sahip akıllı saat kullanılarak insan hareketlerinin sınıflandırılması gerçekleştirilmiştir. Literatür incelendiğinde insan hareketlerinin sınıflandırılması uygulamalarının insan vücuduna yerleştirilen algılayıcılar, akıllı telefonların kullanımının artması ile de akıllı telefonlar ile gerçekleştirildiği görülmektedir. Bu çalışmada algılayıcı verileri insanların gündelik rahatlıkla kullanabilecekleri akıllı saatlerden elde edilmiş ve çevrimiçi hareket sınıflandırma uygulaması telefonda bağımsız çalışabilecek şekilde geliştirilmiştir. Çalışmada ivmeölçer algılayıcısını yanında adımsayar algılayıcısından elde edilen değerler de kullanılarak, sınıflandırmaya olan etkisi karşılaştırılmıştır. Adımsayarın on yöntemden dokuzunda ortalama doğruluk oranını artırdığı gözlemlenmiştir. Gelecek çalışmalarda akıllı saatler ile hareket sınıflandırmasını çeşitli yollarla geliştirmek mümkündür. Çalışmada temizlik yapma sınıfı toz alma ve süpürge kullanma eylemlerini içermektedir. İlerleyen çalışmalarda bu sınıfların ve veri setinde olmayan fakat kullanıcının sıklıkla gerçekleştirebileceği eylemlerin (el sallama, el sıkışma, cisim fırlatma vb.) veri setine eklenmesi çok çeşitli eylemlerin de sınıflandırılmasını sağlayacaktır.

## Teşekkür

Bu çalışma Muğla Sıtkı Koçman Üniversitesi tarafından 16/061 proje numarası ile desteklenmiştir.

## Kaynakça

- [1] Sağbaş, E.A., Ballı, S. 2016. Giyilebilir Akıllı Cihazlar: Dünyü, Bugünü ve Geleceği, Akademik Bilişim Konferansı, 3-5 Şubat, Aydın, Baskıda.
- [2] Su, X., Tong, H., Ji, P. 2014. Activity Recognition with Smartphone Sensors. Tsinghua Science and Technology, 19(3), 235-249.
- [3] Khan A.M., Lee Y.K., 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*, 5172-5175.
- [4] 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.
- [5] Riboni D., Bettini C. 2011. COSAR: hybrid reasoning for context-aware activity recognition. *Personal and Ubiquitous Computing*, 15(3), 271-289.
- [6] Sağbaşı, E.A., Ballı, S. 2016. Akıllı Telefon Sensör Verileri ile Eylem Tanımda Lojistik Regresyon ve kNN Yöntemlerinin Karşılaştırılması, 1st International Conference on Engineering Technology and Applied Science, 21-22 April, Afyonkarahisar, 894-899.
- [7] Chernbumroong S., Atkins A.S., Yu H. 2011. Activity classification using a single wrist-worn accelerometer. In *Software, Knowledge Information, Industrial Management and Applications*, 1-6.
- [8] Kwapisz J.R., Weiss G.M. ve Moore, S.A. 2014. Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2), 74-82.
- [9] Lara, O.D., Pérez A.J., Labrador M.A., 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.
- [10] da Silva F. G., Galeazzo E. 2013. Accelerometer based intelligent system for human movement recognition. In *Advances in Sensors and Interfaces*, 20-24.
- [11] Dadashi, F., Arami, A., Crettenand, F., Millet, G. P., Komar, J., Seifert, L., 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, MIT, Cambridge, USA, 1-6.
- [12] Mortazavi, B. J., Pourhomayoun, M., Alsheikh, G., Alshurafa, N., Lee, S. I., 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, Zürich Switzerland, 33-38.
- [13] Dong, Y., Scisco, J., Wilson, M., Muth, E., Hoover, A. 2014 Detecting periods of eating during free-living by tracking wrist motion. *Biomedical and Health Informatics*, 18(4), 1253-1260.
- [14] 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.
- [15] Wang, S., Chen, C. Ma, J. 2010. Accelerometer based transportation mode recognition on mobile phones. *Wearable Computing Systems (APWCS)*, 44-46
- [16] Shoaib M., Bosch S., Scholten H., Havinga P. J., Incel O. D. 2015. Towards detection of bad habits by fusing smartphone and smartwatch sensors. In *Pervasive Computing and Communication Workshops*, St. Louis, 591-596.
- [17] Weiss G.M., Timko J.L., Gallagher C.M., Yoneda K., Schreiber A.J. 2016. Smartwatch-based activity recognition: A machine learning approach. *Biomedical and Health Information*. 426-429.
- [18] Ballı S., ve Sağbaşı, E.A. 2017 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.
- [19] Chandra B., Gupta M., 2011. Robust approach for estimating probabilities in Naive-Bayes Classifier for gene expression data. *Expert Systems with Applications*, 38(3), 1293-1298.
- [20] Feng T., Timmermans H.J.P. 2010. Comparative Evaluation of Algorithms for GPS Data Imputation. 13th WCTR, 15 Temmuz, Rio de Janeiro, 1-11.
- [21] Sökün H., Kalkan H., Cetişli B. 2012. Classification of physical activities using accelerometer signals. In *Signal Processing and Communications Applications Conference*, 18-20 Nisan, Muğla, 1-4.
- [22] Breiman, L. 2001. Random Forests. *Machine Learning*. 45(1), 5-32.
- [23] Özkan, Y., Selçukcan Erol, Ç. 2015. Biyoenformatik DNA Mikrodizi Veri Madenciliği. *Papatya Yayıncılık Eğitim, İstanbul*, 432s.
- [24] Korb K.B, Nicholson A.E. 2011. Bayesian Artificial Intelligence. 2, David Blei, David Madigan, Marina Meila, Fionn Murtagh, Boca Raton, 452s.
- [25] Frank, E., Wang, Y., Inglis, S., Holmes, G., Witten, I. H. 1998. Using model trees for classification. *Machine Learning*, 32(1), 63-76.
- [26] Zhao, Y., Zhang, Y. 2008. Comparison of decision tree methods for finding active objects. *Advances in Space Research*, 41(12), 1955-1959.
- [27] Moto 360, <http://www.motorola.com/us/products/moto-360> (Erişim Tarihi: 05.04.2016)
- [28] Bieber, G., Peter, C. 2008. Using physical activity for user behavior analysis. In *Proceedings of the 1st international conference on Pervasive Technologies Related to Assistive Environments*, Atina, 15-19 Temmuz, p. 94.

- [29] Use WEKA in your Java code,  
<https://weka.wikispaces.com/Use+WEKA+in+your+Java+code> (Erişim Tarihi: 05.04.2016)
- [30] Sağbaşı E.A., Ballı S. 2016. Akıllı Telefon Algılayıcıları ve Makine Öğrenmesi Kullanılarak Ulaşım Türü Tespiti. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 22(5), 376-383
- [31] Using the Step Counter Sensor,  
[http://developer.android.com/guide/topics/sensors/sensors\\_motion.html#sensors-motion-stepcounter](http://developer.android.com/guide/topics/sensors/sensors_motion.html#sensors-motion-stepcounter) (Erişim Tarihi: 05.04.2016)
- [32] 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.
- [33] Witten I.H., Frank E. 2005. Data mining: Practical machine learning tools and techniques. San Francisco, CA: Morgan Kaufmann Publishers, 525s.
- [34] 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, 57-64.