



**AKILLI BİLEKLİK KULLANARAK  
AKTİVİTE TANIMA UYGULAMALARI**

**Tuba ŞAHİN**

**Yüksek Lisans Tezi  
Bilgisayar Mühendisliği Anabilim Dalı  
Bilim Dalı  
Doktor Öğretim Üyesi Levent BAYINDIR  
2019  
Her hakkı saklıdır**

**ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**AKILLI BİLEKLİK KULLANARAK AKTİVİTE TANIMA  
UYGULAMALARI**

**Tuba ŞAHİN**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
Bilim Dalı**

**ERZURUM  
2019**

**Her hakkı saklıdır**



T.C.  
ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



TEZ ONAY FORMU

**AKILLI BİLEKLİK KULLANARAK AKTİVİTE TANIMA  
UYGULAMALARI**

Doktor Öğretim Üyesi Levent BAYINDIR danışmanlığında, Tuba ŞAHİN tarafından hazırlanan bu çalışma 04./04./2019 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı'nda Yüksek Lisans Tezi olarak ~~oybirliği/oy çokluğu~~ (.../...) ile kabul edilmiştir.

Başkan : *Doc. Dr. Nur Hüseyin KARLIM*

İmza :

Üye : *Dr. Öğr. Üyesi Levent Bayındır*

İmza :

Üye : *Dr. Öğr. Üyesi Ahmet COŞKUNÇAY*

İmza :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu *08/08/2019* tarih ve *32/6.S* . . . . nolu kararı ile onaylanmıştır.

**Prof. Dr. Mehmet KARAKAN Y,**  
Enstitü Müdürü

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

## ÖZET

Yüksek Lisans Tezi

### AKILLI BİLEKLİK KULLANARAK AKTİVİTE TANIMA UYGULAMALARI

Tuba ŞAHİN

Atatürk Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Bilim Dalı

Danışman: Doktor Öğretim Üyesi Levent BAYINDIR

İnsanların günlük hayattaki aktiviteleri hakkında bilgi edinme ihtiyacı gün geçtikçe artmaktadır. Bu ihtiyaca binaen günlük aktivitelerin tespitine yönelik pek çok yöntem (kamera ile hareket tespiti, algılayıcılar ile hareket tespiti vb.) geliştirilmiştir. Günlük hayatta aktivite tanımaya yönelik çalışmalar yaygınlaşırken öte yandan spor, sağlık, inşaat sektörü gibi pek çok alanda da aktivite tanıma önem arz etmektedir. Bu tez çalışmasında ivmeölçer ve pusula algılayıcılarından yararlanılarak spor (koşma, yürüme, araç kullanma, kayak yapma ve snowboard) ve inşaat aktiviteleri (matkapla delme, duvar boyama, musluk sıkma, duvar vidalama, testere ile kesme ve çekiçle delme) için aktivite tanıma gerçekleştirilmiştir. Aktiviteler için algılayıcı verilerinin toplanması için içerisinde Photon geliştirme kartı ve algılayıcılar yer alan bir bileklik kullanılmıştır. Spor ve inşaat aktiviteleri için iki ayrı veri kümesi oluşturulmuştur. Spor aktiviteleri için ivmeölçer algılayıcısından yararlanılarak toplamda on bin veri toplanırken inşaat aktiviteleri ivmeölçer ve pusula algılayıcılarından yararlanılarak toplamda altmış bin veri toplanmıştır. Elde edilen ham veriler işlenerek çeşitli öznitelikler (ortalama, min, max, korelasyon vb.) çıkarılmıştır. Spor aktiviteleri için yirmi iki öznitelik kullanılmış ve inşaat aktiviteleri için kırk dört öznitelik kullanılmıştır. K-en yakın komşu, Nüve Bayes, Rastgele Orman ve Destek Vektör Makineleri sınıflandırma yöntemleri kullanılarak aktivite sınıflandırması gerçekleştirilmiştir. Yöntemlerin uygulanması sonucu oluşan doğruluk yüzdeleri, farklı parametreler ile incelenmiştir. Kullanılan her bir sınıflandırma yöntemi ve aktivite kombinasyonu için %90'ın üzerinde başarı elde edilmiştir. Yapılan çalışma, bildiğimiz kadarıyla, hem spor (snowboard) hem de inşaat için (matkapla delme, vidalama) daha önce kullanılmayan aktivitelerin kullanılması ve inşaat aktivitelerinde aktiviteye göre veri toplama cihazının konumunun değiştirilmemesi yönleriyle literatürdeki mevcut çalışmalardan ayrılmaktadır.

**2019, 61 sayfa**

**Anahtar Kelimeler:** Aktivite tanıma, makine öğrenmesi, yaygın bilişim, nesnelerin interneti

## ABSTRACT

MS Thesis

### ACTIVITY RECOGNITION APPLICATIONS USING SMART WRISTBAND

Tuba ŞAHİN

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

Supervisor: Assist. Prof. Dr. Levent BAYINDIR

The requirement of learning about people's activities in daily life is increasing day by day. Consequently, many methods (motion detection with camera, motion detection with sensors, etc.) have been developed for the detection of daily activities. While studies aimed at recognizing activities in daily life become widespread, it is also important to recognize activities in many fields such as sports, health, and construction sectors. In this study, activity recognition for sports (running, walking, driving, skiing, and snowboarding) and construction activities (drilling, screwdriving, wall painting, hammering, sawing, and tap clamping) was realized by using accelerometer and compass sensors. In order to collect the sensor data for activities, a wristband containing Photon development card and sensors was used. Two separate data sets were created for sports and construction activities. A total of ten thousand data were collected by using accelerometer sensor for sports activities, and sixty thousand data were collected by using accelerometer and compass sensors for construction activities. The raw data obtained were processed, and various features (mean, min, max, correlation, etc.) were extracted for classification algorithms. Twenty-two features were used for sports activities, and forty-four features were used for construction activities. Activity classification was performed using K-nearest neighbor, Nāive Bayes, Random Forest, and Support Vector Machines classification methods. Accuracy percentages obtained from the application of the methods were examined with different parameters. Over 90% success was achieved for each classification method and activity combination. As far as is known, the present study differs from existing studies in the literature in respect to use activities which is not previously used for both sports (snowboarding) and construction (drilling, screwing) and not to change the position of the data acquisition device according to activity in construction activities.

**2019, 61 pages**

**Keywords:** Activity recognition, machine learning, pervasive computing, internet of things

## TEŐEKKÜR

Tezimin konusunun belirlenmesinde, arařtırma ařamasında, yönlendirilmesinde ve tamamlanmasında destek olan deęerli hocam ve tez danıřmanım Sayın Doktor Öğretim Üyesi Levent BAYINDIR'a bana ayırdığı deęerli zamanı ve sağladığı destek için minnettarım.

Tezimin başlangıcından bitimine kadar bana inanan, benden yardımlarını esirgemeyen, her zaman yanımda olan, bildiklerini paylaşan ve bildiklerimi paylaşmamı öğreten annem Meliha KAYTARAN, babam Eyyup KAYTARAN ve canım kardeřlerime,

İkinci ailem dediğim kıymetli kayınpederim Ahmet ŐAHİN'e ve kayınvalidem Nurgül ŐAHİN'e,

Çalıřma sürecimde her türlü deęeđi sağlayan yöneticilerim Ali ARSAN ve Nabi AYDIN'a,

Tez sürecimde gösterdikleri sabır ve verdikleri her türlü destek için can dostlarım dediğim Nursen KELEŐ, Ebru ERDEM, Seda ERDEN ve Selma BAYRAM'a,

Son olarak deęeđini ve güvenini hiç esirgemeyen kıymetli eřim Ramazan Őahin'e sonsuz teőekkür ederim.

**Tuba ŐAHİN**

**Temmuz, 2019**

## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	ix
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Aktivite Tanıma.....	3
1.1.1. Aktivite tanıma sistemlerinin uygulama alanları.....	3
1.1.2. Aktivite tanıma süreci.....	5
1.1.3. Aktivite tanımadaki kullanılan algılayıcılar.....	8
1.1.4. Performans ölçütleri.....	11
1.2. Tezin Araştırma Kapsamı ve Amaçları.....	12
1.3. Organizasyon.....	12
<b>2. KAYNAK ÖZETLERİ.....</b>	<b>14</b>
2.1. Günlük Aktiviteler.....	14
2.2. Spor Aktiveleri.....	20
2.3. İnşaat Aktiviteleri.....	23
<b>3. MATERYAL ve YÖNTEMLER.....</b>	<b>27</b>
3.1. Donanım Bileşenleri.....	27
3.1.1. Particle photon geliştirme kartı.....	28
3.1.2. HMC5883L pusula.....	30
3.1.3. ADXL345 ivmeölçer.....	31
3.1.4. Li-Po batarya.....	32
3.2. Sunucu Uygulaması.....	33
3.3. Aktiviteler.....	35
3.4. Veriler ve Sınıflandırma.....	37
<b>4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....</b>	<b>49</b>
4.1. Spor Aktiviteleri.....	49

4.2. İnşaat Aktiviteleri .....	52
<b>5. SONUÇ ve ÖNERİLER.....</b>	<b>58</b>
KAYNAKLAR .....	60
ÖZGEÇMİŞ .....	63



## KISALTMALAR DİZİNİ

### Kısaltmalar

kNN	k-En Yakın Komşu
NB	Näive Bayes
RO	Rastgele Orman
DVM	Destek Vektör Makinası



## ŞEKİLLER DİZİNİ

<b>Şekil 1.1.</b> Aktivite türleri içerisinde koşma, yürüme, spor yapma, yük taşıma vb. gibi farklı tür aktivitelerin örnek gösterimi .....	3
<b>Şekil 1.2.</b> Mekik çekme, ip atlama, halter kaldırma gibi spor aktivitelerinin örnek gösterimi.....	5
<b>Şekil 1.3.</b> Aktivite tanımada ham verilerin alınarak ön işleme, bölütleme öznelik çıkarma gibi işlemler sonrasında aktivite tanıma işleminin gösterimi.....	6
<b>Şekil 2.1.</b> Aktivite tanımaya yönelik günlük, spor ve iş alanı türündeki aktivitelere bazı örnekler .....	14
<b>Şekil 3.1.</b> Günlük yaşamda akıllı cep telefon taşıma pozisyonları .....	27
<b>Şekil 3.2.</b> Aktivite tanıma için yapılan bileklik ve kol saatine göre boyutunun gösterimi.....	28
<b>Şekil 3.3.</b> Aktivite tanımada kullanılan Photon geliştirme kartı ve bileşenleri .....	30
<b>Şekil 3.4.</b> Aktivite tanıma kullanılan X, Y, Z üç ekseninde manyetik alan ölçümü yapabilen HMC5883L pusula .....	31
<b>Şekil 3.5.</b> Aktivite tanıma kullanılan X, Y, Z Z üç ekseninde koordinat alan ADXL345 algılayıcı .....	32
<b>Şekil 3.6.</b> Aktivite tanıma da kullanılan Li-Po batarya.....	33
<b>Şekil 3.7.</b> Spor aktivitelerinin belirlenmesi için verilerin ivmeölçerden alınıp CSV dosyasına yazılmasına kadar araç süreçlerin gösterimi.....	34
<b>Şekil 3.8.</b> İnşaat aktivitelerinin belirlenmesi için verilerin ivmeölçer ve pusuladan alınıp CSV dosyasına yazılmasına kadar süreçlerin gösterimi .....	35
<b>Şekil 3.9.</b> Aktivite tanıma için yapılan koşma, yürüme, araç kullanma, kayak ve snowboard gibi spor aktiviteleri gösterimi.....	36
<b>Şekil 3.10.</b> İnşaat aktivitelerini tanıma için matkapla delme, çekiçle çakma, testere ile kesme, musluk sıkma, vidalama ve duvar boyama gibi yapılan inşaat aktiviteleri gösterimi .....	37
<b>Şekil 3.11.</b> Photon Spark Core cihazlar için programlama arayüzünün (Spark Cloud) ekran görüntüsü.....	39

<b>Şekil 3.12. a)</b> Aktivite tanıma için kullanılan bilekliğin kapağı açık görüntüsü	
<b>b)</b> Aktivite tanıma için kullanılan bilekliğin kapağı kapalıyken ve bileğe sabitlenmişken görüntüsü .....	40
<b>Şekil 3.13.</b> Çalışmada kullanılan aktivite tanıma süreci .....	41
<b>Şekil 3.14.</b> kNN sınıflandırma yönteminde $k=3$ değeri için uzaklık kullanarak bilinmeyen bir durumu sınıflandırmak.....	45
<b>Şekil 3.15.</b> DVM sınıflandırma yönteminde karar çizgisi ile verileri kümeleme.....	46
<b>Şekil 3.16.</b> DVM sınıflandırma yönteminde karmaşık yapıdaki nesnelerin tam olarak ayrılması .....	47
<b>Şekil 4.1.</b> Kayak (a) ve Snowboard (b) aktivitelerinin öznelik dağılımı .....	51
<b>Şekil 4.3.</b> kNN algoritmasının $k$ değerine göre değişimi.....	54

## ÇİZELGELER DİZİNİ

<b>Çizelge 2.1.</b> Günlük aktivitelere yönelik yapılan çalışmaların algılayıcı, öznitelik, sınıflandırma ve performans belirlenmesine yönelik değerlendirmesi.....	17
<b>Çizelge 2.2.</b> Spor aktivitelerine yönelik yapılan çalışmaların algılayıcı, öznitelik, sınıflandırma ve performans belirlenmesine yönelik yapılan değerlendirme.....	21
<b>Çizelge 2.3.</b> İnşaat aktivitelerine yönelik yapılan çalışmaların algılayıcı, öznitelik, sınıflandırma ve performans belirlenmesine yönelik değerlendirme.....	24
<b>Çizelge 3.1.</b> Particle web sayfası Spark Cloud menüleri .....	38
<b>Çizelge 3.2.</b> Aktivite tanımada kullanılan öznitelikler ve formülleri .....	43
<b>Çizelge 3.3.</b> Ham veriye öznitelik dönüşümü uygulandıktan sonra elde edilen veri kümesinden örnek olarak alınan değerler .....	44
<b>Çizelge 4.1.</b> Spor aktiviteleri olarak yapılan koşma, yürüme, araç kullanma, kayak ve snowboard aktivitelerinin sınıflandırma yöntemlerine göre elde edilen doğruluk yüzdeleri .....	50
<b>Çizelge 4.2.</b> İnşaat aktivitelerinden matkapla delme, boyama, vidalama, testere ile kesme, musluk sıkma ve çekiçle çakma için sınıflandırma yöntemlerine göre elde edilen doğruluk yüzdeleri .....	52
<b>Çizelge 4.3.</b> Aktivite tanımada kullanılan ivmeölçer ve pusula verilerine göre sınıflandırma sonuçları .....	53
<b>Çizelge 4.4.</b> kNN, DVM, RO ve NB sınıflandırma yöntemlerinin performans ölçütlerine göre doğruluk oranındaki değişim .....	54
<b>Çizelge 4.5.</b> kNN sınıflandırma yönteminde çapraz doğrulamanın doğruluk oranına etkisi.....	55
<b>Çizelge 4.6.</b> RO sınıflandırma yönteminde iterasyon sayısının doğruluk oranına etkisi.....	55
<b>Çizelge 4.7.</b> Aktivite tanımada kullanılan NB yönteminin karmaşıklık matrisi.....	56
<b>Çizelge 4.8.</b> Aktivite tanımada kNN yönteminin karmaşıklık matrisi .....	56
<b>Çizelge 4.9.</b> Aktivite tanımada RO yönteminin karmaşıklık matrisi.....	56
<b>Çizelge 4.10.</b> Aktivite tanımada DVM yönteminin karmaşıklık matrisi .....	57

## 1. GİRİŞ

İlk olarak 1999 yılında Kevin Ashton tarafından kullanılan Nesnelerin İnterneti'nin popülerliği hızla artmış ve günümüzün yaygın teknolojileri arasında yerini almıştır (Kevin 2009). Nesnelerin İnterneti'ne akıllı kameralar, akıllı termostatlar, akıllı saatler ve akıllı bileklikler örnek verilebilir (Bıçakçı 2018). Nesnelerin İnterneti, aktivite tanıma çalışmalarında da önemli bir yere sahiptir. Aktivite tanımda genellikle günlük aktivitelerin belirlenmesine yönelik çalışmalar yapılmıştır. Fakat son zamanlarda günlük aktivitelerin yanısıra spor ve iş alanı (saha) aktivitelerinin belirlenmesi için yapılan çalışmalar da yaygınlaşmaktadır.

Aktivite tanıma bir veya daha fazla kullanıcı tarafından gerçekleştirilen fiziksel eylemi, kullanıcı etkinliği sırasında bir dizi gözlemden geçirerek tanıma eylemidir (Bin *et al.* 2012). Son zamanlarda, çok sayıda farklı uygulamalara hitap eden aktivite tanımaya yönelik farklı çalışmalar görülmektedir. İnsan aktivitesinin tanınması, bağımlı kişi takip sistemleri (yaşlılar, çocuklar vb.), sağlık takip sistemleri, performans analizi sistemleri (inşaat sektörü), spor aktivitesi gibi çok çeşitli uygulamalara katkıda bulunan, kişilerin günlük rutinlerini değiştiren önemli bir teknoloji haline gelmiştir. Bu teknolojik gelişmeye binaen aktivite tanıma konusundaki araştırmalar hızlanmış ve aktivite tanıma uygulamalarına yönelik çalışmalarda karşılığını bulmuştur.

Artan insan nüfusu, şehir trafiği ve çevre koşullarının uygun olmayışı insanların sağlığını olumsuz etkilenmektedir. Bu nedenle spor aktivitelerinde de aktivite tanıma çalışmaları giderek artmaktadır. Adım sayarlar ve profesyonel spor aktivitesi tespiti (tenis, futbol, kayak, snowboard vb.) gibi pek çok alanda aktivite tespit yöntemi geliştirilmiştir (Avci *et al.* 2010).

Nesnelerin İnterneti'nin aktivite tanıma ile buluşması, aktivite tanıma alanlarından bir diğeri olan inşaat sektöründe de yapılan çalışmaları artırmaktadır. İnsan gücüne de ihtiyaç duyulan inşaat sektöründe çalışanların performansı takip edilemediği için

verimlilik genellikle düşmektedir. İnsan aktivitesi, inşaat projesinin %30-%50'sini oluşturduğu için verimlilik, zamanlama ve bütçe kontrolünde anahtar faktördür (Akhavian *et al.* 2015). Sahadaki çalışanların performanslarını yönetmenin pek çok yöntemi bulunmaktadır. Bu yöntemlerin en etkinlerinden biri çalışanların sahadaki faaliyetlerini izlemek, yapılan işi gerçek zamanlı olarak analiz etmek ve iş akışını dinamik olarak optimize etmektir.

Çalışanların faaliyetlerini izlemek ve bilgi toplamak için sahayı analiz eden elemanlar gözlem, anket veya görüşme şeklinde sahayı yönetebilmektedir. Gerekli bilgiler toplandıktan sonra toplanan veriler manuel olarak analiz edilmektedir. Fakat bu yöntem zamansal olarak yoğun emek gerektirmekle birlikte hataya daha açık olmaktadır. Bu durum nedeniyle inşaat işçilerinin faaliyetlerinin otomatik olarak takibine ve analizine ihtiyaç vardır. Bu ihtiyaçtan ötürü kameralardan çalışanların hareketlerini takip ederek ve makine öğrenmesi kullanılarak performans analizi yapılmaktadır (Rebolj *et al.* 2008). Bu yöntemle çalışanların hareketlerinin tespitine yönelik kayda değer başarılar elde edilmiş olsa da inşaat alanındaki aktivitelerin çeşitliliği, kamera açısının farklı durumlar için uygun olarak ayarlanmasının zorluğu ve görüntüyü etkileyen ışık gibi ortam faktörleri, bu çalışmaların başarısını ve yaygınlaşmasını etkileyen önemli etkenlerdendir.

Belirtilen durumlardan ötürü aktivite tanıma da giyilebilir algılayıcılardan (GPS, mikrofon, kamera, jiroskop, ışık ve ısı, pusula, manyetik algılayıcı, ivmeölçer vb.) yararlanılması, işlem sırasında aksamayan ve bunun sonucunda da daha doğru veriye ulaşan bir yöntem olacağı düşünülmektedir. Bu nedenle, işçilerin yaptıkları işleri aksatmadan kullanabileceği ve içerisinde algılayıcı olan bileklik tercih edilmektedir. Kullanılan bileklik ve içerisinde yer alan algılayıcılar vasıtasıyla belirlenen aktiviteler yapılarak aktivite verileri toplanmaktadır. Elde edilen verilerin öznelikleri çıkarılarak daha anlamlı verilere dönüştürülmektedir. Bu veriler ilgili sınıflandırma yöntemlerinden geçirilerek aktivite tanımlama işlemi yapılmaktadır.

## 1.1. Aktivite Tanıma

Genel olarak aktivite tanıma, insanların karmaşık hareketlerinin yatay ve dikey gibi eksen değerlerine göre hangi eyleme ait olduğunun belirlenmesidir (Clarkson *et al.* 2000). Duvar boyama aktivitesine dikey eksen hareketi, vidalama aktivitesine ise yatay ve dikey eksenleri hareketi örnek verilebilir.

Günlük hayatta koşma, yürüme ve araç kullanma gibi aktivitelerin tespitine yönelik çalışmalar sıkça yapılmaktadır. Günlük aktivitelerin dışında iş ve sağlık alanında da aktivite tespitine yönelik çalışmalar giderek yaygınlaşmaktadır. Şekil 2.1'de çeşitli insan aktivitelerine örnekler verilmiştir.



**Şekil 1.1.** Aktivite türleri içerisinde koşma, yürüme, spor yapma, yük taşıma vb. gibi farklı tür aktivitelerin örnek gösterimi

### 1.1.1. Aktivite tanıma sistemlerinin uygulama alanları

#### Sağlık

İnsanların rutin işlerini yapabilmesi ve günlük yaşantısını rahat bir şekilde devam ettirebilmesi için sağlığını koruması gerekmektedir. Bunun için de insan vücudunun,

fiziksel aktiviteler yapmaya ihtiyacı vardır. Fiziksel aktiviteler uzun zamandır sağlıklı yaşam tarzının önemli bir bileşeni olarak görülmektedir (Helmrich *et al.* 1991). Aktivitelerin yapılmasının aksaması vücutta çeşitli hastalıkların tetiklenmesine neden olmaktadır. Fiziksel aktivite ve kronik hastalıkların risk faktörleri arasındaki ilişki, yetişkinlerde belgelenmiştir (Ott *et al.* 2000). Belirtilen durumlar değerlendirildiğinde fiziksel aktivitelerin günlük hayattaki önemi anlaşılmaktadır.

Akıllı cihazların hayatımızda yaygınlaşmasıyla algılayıcıların kullanımı sağlık alanında yapılan çalışmalarda da yer almıştır (Chen *et al.* 2005). Sağlık problemlerine yönelik çarpınma ve düşme tespiti bu duruma örnek olarak verilebilir (Lara *et al.* 2012). Giyilebilir algılayıcılar ile aktivitenin tanınması ve belirlenen aktivitelerin doğru ya da yanlış yapıldığına dair geri bildirim alınması sağlanabilmektedir (Ermes *et al.* 2008).

### **İş Alanı**

Aktivite tanıma, günlük aktivitelerin tanınmasının yanısıra iş alanı aktivitelerinde de önem arz etmektedir. Bunun önemli nedenlerinden biri manuel yöntemlerle yapılan performans değerlendirmelerinin gerçeği çok fazla yansıtmamasıdır (Akhavian *et al.* 2015). Aktivite tanıma uygulamaları iş alanında etkili çalışma ve çalışma zamanının doğru analizi için önemlidir. Ayrıca aktivite tanıma çalışanların çalışma performanslarının izlenmesi, iş alanında genel verimlilik ölçümü, ilerleme değerlendirmesi, işgücü eğitim programları, güvenlik ve sağlık yönetimi gibi konularda da önem arz etmektedir.

### **Spor**

Günlük hayatta sağlıklı yaşamın normal seyrinde gidip gitmediğini kontrol edebilmek için spor alanında aktivite tanıma çalışmalarına ihtiyaç duyulmuştur. Sağlıklı yaşam için gerekli olan spor aktiviteleri (koşma, yürüme, halter kaldırma, ip atlama, mekik çekme vb.) çeşitli uygulamalarla takip edilebilmektedir (Şekil 2.2). Teniste kaç vuruş yapıldığının hesaplanması, futbolda ayak hareketlerinin yanlışlığını veya kayakta hangi

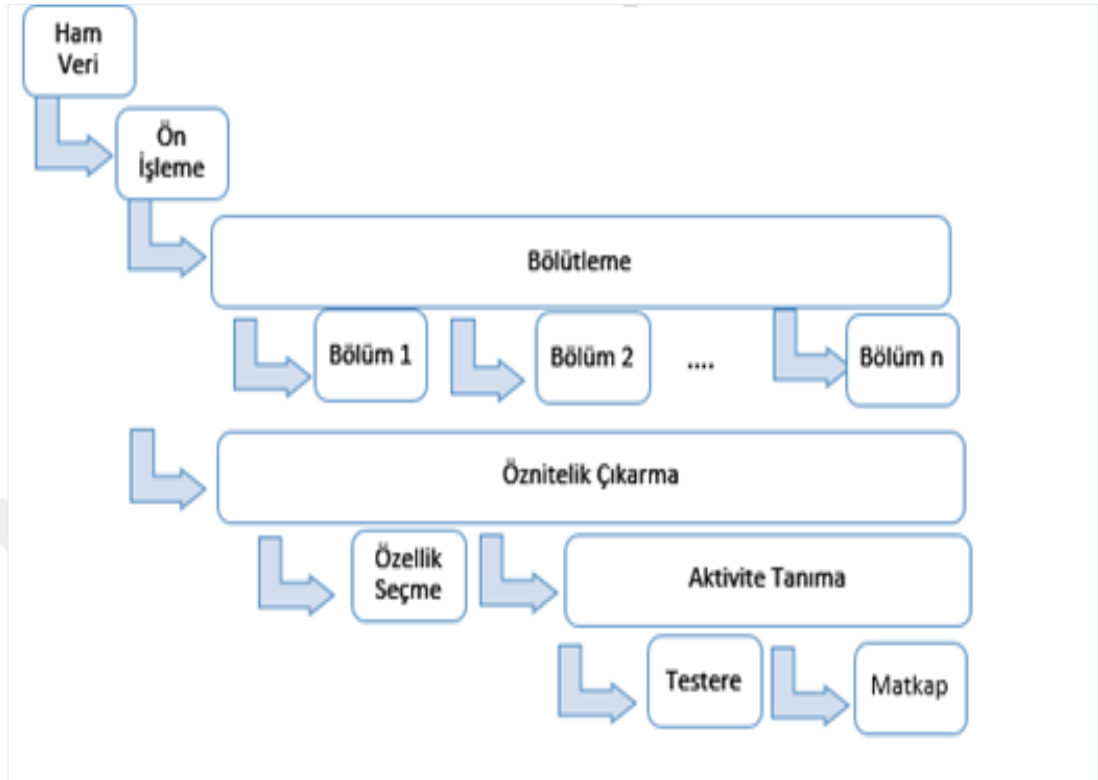
salınım hareketinin ne kadar yapıldığı gibi aktivite durumlarının tespitinin yapılması amaçlanmaktadır (Mitchell *et al.* 2013).



**Şekil 1.2.** Mekik çekme, ip atlama, halter kaldırma gibi spor aktivitelerinin örnek gösterimi

### 1.1.2. Aktivite tanıma süreci

Aktivite tanıma çalışmalarında, algılayıcılardan veri alma veya kameradan görüntü alma gibi farklı yöntemler kullanılmaktadır. Bu yöntemler farklı olsa da aktivite tanıma ortak bir süreç kapsamında tanımlanabilmektedir. Ham veriden başlayarak bu verinin ön işleme, bölütleme, öznitelik çıkarımı, öznitelik seçimi ve sınıflandırma işlemlerinden geçerek aktivite tanımlaması Şekil 1.3'te görüldüğü gibi gerçekleştirilmektedir (Avcı *et al.* 2010).



**Şekil 1.3.** Aktivite tanımada ham verilerin alınarak ön işleme, bölütleme öznitelik çıkarma gibi işlemler sonrasında aktivite tanıma işleminin gösterimi

### Ön işleme

Veri ön işleme, ham verilerin anlaşılır formata dönüştürülmesini içeren veri madenciliği tekniğidir. Çoğu zaman gerçek dünya verileri eksik ve tutarsız olmakta veya hata içermektedir. Veri ön işleme, bu tür sorunları çözenin kanıtlanmış bir yöntemidir. Veri ön işleme, daha sonraki işlemler için ham verileri hazırlamayı amaçlamaktadır (Batista *et al.* 2003).

Veri ön işleme; temizleme, örnek seçimi, normalleştirme, dönüştürme, özellik çıkarma ve seçme gibi işlemleri içermektedir.

## **Bölütleme**

Bölütleme bir veriyi belli boyutlu pencerelere bölerek, veriden özniteliklerin çıkarılmasını kolaylaştıran işlemdir. Pencere kaydırma algoritması bölütlemeye örnek verilebilir.

## **Öznitelik Seçme**

Ham verinin direk olarak sınıflandırma amaçlı kullanımı, fazladan veya alakasız bilgiler içeren büyük bir özellik hesaplama yükü oluşturabilir, sınıflandırma işlemini yavaşlatabilir ve aktivite tanıma doğruluğunu olumsuz yönde etkileyebilir. Bu nedenle, en uygun özellikleri seçmek için teknikler uygulamak etkili sınıflandırma da önemli bir faktördür (Suto *et al.* 2017). Bu durum sınıflandırma algoritmalarının performansının, güçlü özelliklere bağlı olduğunu gösterir. Özellik seçiminin amacı, önemli bir sınıflandırma doğruluğu kaybı olmadan özellik sayısını en aza indirmektir.

## **Öznitelik Çıkarma**

Öznitelik çıkarma, büyük bir veri kümesinin doğru bir şekilde tanımlanması için gereklidir. Karmaşık verilerin analizi yapılırken en büyük sorunlardan biri ilgili değişkenlerin sayısından kaynaklanır. Çok sayıda değişken içeren veri kümeleri analiz için genellikle yüksek miktarda bellek ve hesaplama gücü gerektirmektedir. Ayrıca eğitim örneğini aşan ve yeni numunelere yetersiz şekilde genelleyen bir sınıflandırma algoritmasını da gerektirir (Suto *et al.* 2017). Verileri uygun doğrulukla tanımlamak için özellik çıkarımı, bu problemleri aşmak ve değişkenlerin birleşimlerini oluşturma yöntemleri için genel bir terimdir.

## Sınıflandırma

Aktivite tanımadaki işlem adımlarının sonuncusu sınıflandırmadır. Bu adımda aktiviteler kategorilere ayrılarak sınıflandırma işlemi gerçekleştirilir. Veriler bir dizi öğrenme yöntemi kullanılarak eğitilir ve daha sonra bir dizi gözlemlenmemiş test verisi kullanılarak değerlendirilir.

Yaygın kullanılan sınıflandırma yöntemlerinden bazıları şunlardır:

- k-en Yakın Komşu
- Destek Vektör Makineleri
- Nâive Bayes
- Rastgele Orman
- Karar Ağacı
- Sınır Ağları
- Bulanık Mantık (FL)

### 1.1.3. Aktivite tanımada kullanılan algılayıcılar

Algılayıcılar genel olarak ortamdaki değişiklikleri kayıt eden cihazlardır. Nesnelerin internetinin yaygınlaşmasıyla algılayıcıların aktivite tanıma gibi problemlerde kullanımı artmıştır. Bunlardan bazıları aşağıda kısaca bahsedildiği gibidir.

### İvmeölçer

Bir nesnenin hızındaki değişim oranı olan ivmeyi ölçen algılayıcıdır. İvme, saniye karedeki metre ( $m / s^2$ ) veya G kuvveti olarak ( $g$ ) ölçülür. Dünya gezegeninde tek bir G kuvveti vardır ve  $9,8 m / s^2$ 'ye eşittir. Ancak bu yükseklik ile değişebilir. İvmeölçerler statik veya dinamik hızlanma kuvvetlerini algılayan elektromekanik cihazlardır. Statik

kuvvetler yerçekimini içerirken, dinamik kuvvetler titreşimleri ve hareketi içerebilir. İvmeölçer üç eksenle ivmeyi ölçebilir (Wilde *et al.* 2010).

### **Jiroskop**

Yön bulmak veya yön değerini ölçmekte kullanılır. Bazı donanımsal sistemlerde denge sağlayan parçalardır. Dönerken açısal hızını koruyabilir. Açısal momentumu koruma prensibine dayanarak, momentum uyumunu ölçmek veya korumak için kullanılan bir algılayıcıdır. Açısal momentumun korunumu prensibi üzerine çalışır ve kendi başına hareket etmekte serbest olan bir eksenle desteklenen bir çıkırıktan oluşur. Döner tekerlek veya rotor, gimbal adı verilen tek bir eksen etrafında dönmeyi sağlayan döner bir destek üzerine monte edilmiştir.

Uçaklar, uzay araçları ve gemiler için vazgeçilmez bir cihazdır. Uçak ve uzay araçlarında otomatik uçuş ve rota bulmada yardımcı olurken gemilerde dalga hareketlerinin tespitinde kullanılır. Teknolojinin gelişmesiyle cep telefonları akıllı saatler ve akıllı bileklikler gibi teknolojilerde de kullanılmıştır.

### **Barometre**

Atmosferdeki havanın ağırlığını ölçen ve yaygın olarak kullanılan bir ölçüm aracıdır. Hava istasyonlarında bulunan temel algılayıcılardan biridir.

Barometre, cam tüp içindeki cıva ağırlığını atmosferik basınca karşı dengeleyerek çalışır. Atmosferik basınç temel olarak rezervuarın üstündeki atmosferdeki havanın ağırlığıdır. Bu nedenle cıva seviyesi, cam tüp içindeki cıva ağırlığı, rezervuarın üzerindeki havanın ağırlığına tam olarak eşit oluncaya kadar değişmeye devam eder. İkisi hareket etmeyi kestikten ve dengelendikten sonra, basınç dikey civatada ki cıva yüksekliğindeki değeri okuyarak kaydedilir.

Cıva ağırlığı atmosferik basınçtan düşükse, cam tüp içindeki cıva seviyesi artar. Yüksek basınçlı alanlarda, hava, çevresindeki alanlara akabileceğinden daha hızlı bir şekilde yeryüzünün yüzeyine doğru batar. Yüzeyin üstündeki hava moleküllerinin sayısı arttıkça, bu yüzey üzerinde kuvvet uygulayacak daha fazla molekül vardır. Haznenin üstünde artan hava ağırlığı ile cıva seviyesi daha yüksek bir seviyeye yükselir.

Cıva ağırlığı atmosferik basınçtan fazlaysa, cıva seviyesi düşer (düşük basınç). Alanın üstündeki hava moleküllerinin sayısı azaldığından, bu yüzey üzerinde kuvvet uygulayacak daha az molekül vardır. Rezervuarın üstünde düşük bir hava ağırlığı varken, cıva seviyesi daha düşük bir seviyeye düşer.

### **Pusula (Manyetik Algılayıcı)**

Pusula denilen manyetik algılayıcı manyetik akı, manyetik kuvvet ve yön gibi manyetik alandaki değişiklikleri algılar. Var olan manyetik alan ve algılayıcılardan değişiklik ve değişikliklerle ilgili toplanan veriler hakkındaki bilgiden pek çok şey bilinir. Dönme, açılar, yön, varlık ve elektrik akımı hepsi izlenebilir. Manyetik algılayıcılar, tüm manyetik alanı ölçen ve alanın vektör bileşenlerini ölçen iki gruba ayrılır. Vektör bileşenleri, manyetik alanın ayrı noktalarıdır. Bu algılayıcıları oluşturmak için kullanılan teknikler, çeşitli fizik ve elektronik bileşimlerini içerir. Çoğu manyetik algılayıcı, endüstriyel işlemlerde, navigasyon araçlarında ve bilimsel ölçümlerde kullanılır.

### **Işık algılayıcısı**

Gün ışığının yoğunluğuna göre çalışan özel bir algılayıcıdır. Fotovoltaik hücre, fototransistör, fotoresistör, fototüp, fotomultiplier tüp ve fotodiyot vb. gibi çeşitli ışık algılayıcısı türleri vardır. Ancak, Işık Bağımlı Direnç (LDR) veya foto direnç , otomatik ışık algılayıcı devresinde kullanılan özel bir ışık algılayıcı türüdür. Bu ışığa bağlı dirençler pasiftir ve herhangi bir elektrik enerjisi üretmez. Ancak, ışığa bağlı direnç, gün ışığı yoğunluğu değiştikçe değişmektedir (LDR'de aydınlatılan ışığa bağlı olarak). LDR,

doğada engebeli olduğu gibi, kirli ve sert dış ortamlarda da kullanılabilir. Bu nedenle, dış aydınlatma ve otomatik sokak aydınlatma devreleri için diğer ışık algılayıcılarına kıyasla LDR tercih edilir.

#### 1.1.4. Performans ölçütleri

Aktivite tanımada çeşitli performans ölçütleri kullanılmaktadır. Bunlara örnek olarak 'Doğruluk' ve 'Kesinlik' verilebilir.

Performans ölçütleri türlerinde formüllerde yer alan TN, FN, TP, FP değerleri sırasıyla aşağıdaki şekilde tanımlanmaktadır.

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

Performans ölçütleri olarak doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F ölçütü (F measure) türleri vardır.

Doğruluk,  $(TP + TN) / (TP + TN + FP + FN)$  (doğru sınıflandırılmış örnek sayısının tüm örneklere olan oranı) formülü ile gösterilmektedir.

Kesinlik =  $TP / (TP + FP)$ , gerçek pozitiflerin tüm pozitiflerin toplamına oranıdır.

Geri çağırma =  $TP / (TP + FN)$ , gerçek pozitiflerin gerçek pozitifler ile yanlış negatiflerin toplamına oranıdır.

F Ölçüsü =  $2 \times (\text{Duyarlılık} * \text{Kesinlik}) / (\text{Duyarlılık} + \text{Kesinlik})$  ile gösterilmektedir.

Yani kesinlik ve duyarlılığın harmonik ortalamasıdır (Çoşkun *et al.*).

## 1.2. Tezin Araştırma Kapsamı ve Amaçları

Aktivite tanıma çalışmalarında yaygın olarak günlük hayattaki aktiviteleri tespiti yönelik çalışmalar yapılmaktadır. Koşma, yürüme, oturma, kalkma gibi eylemler üzerine yapılan çalışmaların artmasıyla, aktivite tanıma kapsamı genişletilerek araç kullanma, bisiklete binme, bilgisayarda çalışma, kayak yapma gibi aktiviteler de bu kapsam içerisinde yer almıştır.

Bu tez çalışmasında, spor aktiviteleri ve inşaat sektörüne özel bazı aktivitelerin, algılayıcıdan alınan veriler kullanılarak aktivite tanıma işlemi gerçekleştirilmiştir. Spor aktivitesi olarak; yürüme, koşma, araç kullanma, kayak yapma aktivitelerinin tanınması hedeflenmiştir. Ayrıca literatürde yer almayan snowboard aktivitesinin de tanınması hedeflenmiştir. Aktivite verileri, yirmi beş yaşında 1 bayan (yürüme, koşma aktivitelerini toplamak için) ve altı yıllık spor deneyimi bulunan yirmi beş yaşında 2 erkek (araç kullanma, kayak ve snowboard verilerini toplamak için) olmak üzere üç kişi tarafından toplanılmıştır. İnşaat aktivitesi olarak; matkapla delme, vidalama, testere ile kesme, duvar boyama, çekiçle çivi çakma ve musluk sıkma aktiviteleri belirlenmiştir. İnşaat aktivite verileri, on sekiz yıl inşaat işleri deneyimi olan otuz altı yaşında erkek usta tarafından toplanılmıştır.

## 1.3. Organizasyon

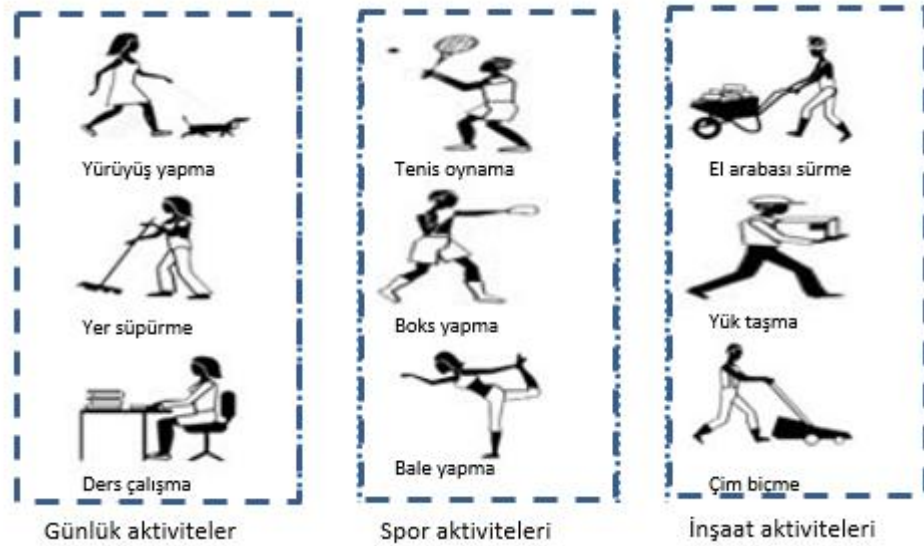
Bu çalışmanın devamındaki akış düzeni aşağıdaki gibidir.

- Bölüm 2’de aktivite tanıma alanında yapılan çalışmalardan bahsedilmektedir. Mevcut çalışmalar günlük aktiviteler, spor aktiviteleri ve inşaat aktiviteleri olmak üzere üç alt başlıkta incelenmektedir.
- Bölüm 3’te materyal ve yöntemler başlığı altında kullanılan donanım parçalarından ve sunucu uygulamasından bahsedilmektedir. Ayrıca toplanılan veriler ve kullanılan sınıflandırma yöntemlerinden bahsedilmektedir.
- Bölüm 4’te deneysel sonuçlardan bahsedilmektedir.
- Bölüm 5’te sonuç ve öneriler yer almaktadır.



## 2. KAYNAK ÖZETLERİ

Teknolojinin gelişmesiyle beraber insanların yaptığı aktiviteleri takip etme istediği artmaktadır. Bunun için günlük aktivitelere yönelik adım sayar, kalori hesapla gibi uygulamalar yapılmıştır. İnsanlar günlük aktivitelerin yanı sıra spor ve iş alanı aktivitelerinin tespitini yapabilmek ve bu aktivite tespiti sonucunda analizler yapabilmek istemektedirler (Şekil 2.1).



**Şekil 2.1.** Aktivite tanımaya yönelik günlük, spor ve iş alanı türündeki aktivitelere bazı örnekler

### 2.1. Günlük Aktiviteler

Günlük fiziksel aktivitelerin ölçümü, günlük yaşam koşullarında kullanılacak objektif ve güvenilir bir teknik gerektirmektedir. Algılayıcıların yaygınlaşmasıyla günlük aktivitelerin takibinde kullanılan ve üç eksenli ivmeölçer içeren birçok aktivite tanıma sistemi geliştirilmiştir. Çizelge 2.1’de günlük aktivitelere yönelik yapılan bazı çalışmalar gösterilmektedir. Çizelgede veriler hangi özniteliklerden geçirilerek ve hangi sınıflandırma yöntemleri kullanılarak ne kadar performans elde edildiğini göstermektedir.

Lee ve arkadaşları aktivite tanımaya yönelik yaptıkları çalışmalarında Android tabanlı cep telefonu ve bu telefon içerisinde yer alan ivmeölçeri kullanmıştır. Durma, koşma, yürüme, merdiven inme, merdiven çıkma gibi aktiviteler sırasında telefonun ivmeölçer verileri alınarak aktivitelerin tespiti hedeflenmiştir. Çalışmada belirlenen her aktivite için belli süre veri toplanmıştır. Toplanılan veriler x, y, z eksen verilerine Hiyerarşik HMM sınıflandırma yöntemi uygulanarak merdiven inme ve çıkma eylemleri arasında bir karışıklık olduğu belirlenmiştir.

Günlük aktiviteler içerisinde yer alan koşma, yürüme, bisiklete binme ve araba kullanma gibi aktivitelerin tespitine yönelik Siirtola ve arkadaşlarının yaptıkları çalışmada Android işletim sistemi destekli cep telefonu kullanılarak veri toplanmaktadır. Belirledikleri aktiviteleri aktif ve aktif olmayan şeklinde gruplayan Siirtola ve arkadaşları ivmeölçer ve manyetik algılayıcıdan yararlanarak veri toplamışlardır. İki algılayıcıdan alınan verilerin ivme büyüklüğü, standart sapma, ortalama, minimum, maksimum gibi öznitelikleri çıkarılarak karar ağacı, kNN, QDA sınıflandırma yöntemleriyle aktivite tespiti noktasında analizi yapılmıştır. Analiz sonucunda %95,4 doğruluk oranı elde edilmiştir.

Lan ve arkadaşları ise yürüme, koşu bandı, oturma, uzanma, ayakta durma, merdiven inip /çıkma gibi aktiveleri belirlemeye yönelik yaptıkları çalışmada 7 erkek ve 1 bayan olarak veri toplanmıştır. Telefonun ivmeölçer algılayıcısından veri alınarak aktivite verileri toplanmıştır. SVM, J48, NB sınıflandırma yöntemleri kullanılarak %95 doğruluk elde edilmiştir.

Pirttikangas ve arkadaşları bilek, göğüs ve diz kapağına yerleştirdikleri ivmeölçerden 17 gün boyunca veri alarak aktivite tanınması yapılması hedeflenmiştir. El ile yazma, TV izleme, bir şeyler içme, merdiven inip/çıkma olarak belirledikleri günlük aktivitelerin tespiti için kNN sınıflandırma yöntemi kullanılarak %90.6 doğruluk elde edilmiştir.

İvmeölçer algılayıcı kullanılarak günlük aktivite tanımaya yönelik yapılan bir diğer çalışma ise Parkka ve arkadaşların yürüme, koşma, bisiklete binme aktivitelerinin

belirlenmesi hedeflenmiştir. İvmeölçerden alınan verilerin ortalama, varyans, medyan, çarpıklık, kurtosis gibi öznitelikleri çıkarılmıştır. Karar ağacı sınıflandırma yöntemi sonucu %86 doğruluk oranı elde edilmiştir.

Parkka ve arkadaşları ile benzer aktiviteler üzerine çalışan Bonomi ve arkadaşları ivmeölçer kullanarak yürüme, koşma, bisiklete binme aktivitelerinin tespitini hedeflemiştir. Belirlenen aktivitelerden alınan verilerin ortalama, standart sapma, tepeden tepeye uzaklık, güç, frekans gibi öznitelikleri çıkarılmıştır. Öznitelikleri çıkarılan veriler Karar ağacı sınıflandırma yönteminden geçirilerek %93 doğruluk oranı elde edilmiştir.

Gjoreski ve arkadaşları aktivite tanıma için ivmeölçer kullanarak uzanma, oturmak, ayakta durmak gibi dinamik ve statik şeklinde gruplanabilecek aktiviteleri belirlemişlerdir. Toplanan verilerin oryantasyon, ortalama ve standart sapma gibi öznitelikleri çıkarılmıştır. Öznitelikli veriler Karar ağacı, Rasgele Orman, Naive Bayes sınıflandırma yöntemlerinden geçilerek %99 başarı elde edilmiştir.

**Çizelge 2.1.** Günlük aktivitelere yönelik yapılan çalışmaların algılayıcı, öznitelik, sınıflandırma ve performans belirlenmesine yönelik değerlendirmesi

Referans	Algılayıcı	Aktivite(ler)	Yöntem(ler)	Öznitelik(ler)	Performans
Lee ve arkadaşları	İvmeölçer	Durma, koşma, yürüme, merdiven inme, merdiven çıkma	Hiyerarşik HMM	x, y, z ivme değerleri	-
Siirtola ve arkadaşları	İvmeölçer	Yürüme, koşma, bisiklete binmek, araba sürmek, durma	Karar ağacı, kNN, QDA	İvme, standart sapma, ortalama, minimum, maksimum	%95,4 doğruluk
Zhixian ve arkadaşları	İvmeölçer	Yürüme, normal yürüme, yavaş yürüme, yürüyen merdivenle yukarı çıkma/ aşağı inme	J48, karar ağacı	Ortalama, büyüklük, varyans, kovaryans, enerji	%20-25 arasında enerji tasarrufu
Lan ve arkadaşları	İvmeölçer	Yürüme, koşu bandı, oturma, uzanma, ayakta durma, merdiven inip /çıkma	DVM, J48, NB	Ortalama, kovaryasyon, enerji	%95 doğruluk

**Çizelge 2.1.** (devam)

Referans	Algılayıcı(lar)	Aktivite(ler)	Yöntem(ler)	Öznitelik(ler)	Performans
Pirttikangas ve arkadaşları	İvmeölçer	El ile yazma, TV izleme, bir şeyler içme, merdiven inip çıkma	kNN	Ortalama, minimum, maksimum	%90,6 doğruluk
Parkka ve arkadaşları	İvmeölçer	Yürüme, koşma, bisiklete binme	Karar ağacı, yapay sinir ağı	Ortalama, varyans, medyan, çarpıklık, kurtosis	%86 doğruluk
Bonomi ve arkadaşlar	İvmeölçer	Yürüme, koşma ve bisiklete binme	Karar ağacı	Ortalama, Standart sapma, çapraz korelasyon, frekans	%93 doğruluk

Çizelge 2.1. (devam)

Referans	Algılayıcı(lar)	Aktivite(lar)	Yöntem(lar)	Öznitelik(lar)	Performans
Gjoreski ve arkadaşları	İvmeölçer	Uzanma, oturmak, ayakta durmak	Karar ağacı, RO, NB	Oryantasyon, Ortalama Standart sapma	%99 doğruluk
Mathie ve arkadaşları	İvmeölçer	Düşme, yürüyüş, geçiş, oturma, durma ve uzanma	Karar ağacı	Sinyal büyüklüğü alanı, ortalama ivme	%87 doğruluk
Pierluigi Casale ve arkadaşları	İvmeölçer	Merdiven inme çıkma, yürüme, konuşmak, ayakta durmak, bilgisayarda çalışma	Rastgele Orman	Ortalama değeri, min, max değeri, standart sapma	%94 doğruluk
Ryder ve arkadaşları	İvmeölçer, GPS	Yürüme, koşma, bisiklete binme, araba sürme, sabit durma	Karar ağacı	Varyans, ortalama, FFT katsayıları	-

## 2.2. Spor Aktivelere

Fiziksel aktivitenin insanların refahı üzerinde olumlu etkisi vardır ve ayrıca kronik hastalıkların oluşumunu azaltabilir (Mitchell *et al.* 2013). Giyilebilir algılayıcılar ile yapılan spor aktivitelerine yönelik veriler kişiye günlük yaşantısıyla ilgili geri bildirim yapmaktadır. Bunun için spor aktivitelerinin belirlenmesine yönelik çalışmalar önemlidir. Çizelge 2.2’de spor aktivitelerine yönelik yapılan çalışmalar görülmektedir. Çizelge incelendiğinde hangi özneliklerin kullanıldığı, hangi sınıflandırma yöntemleri kullanıldığı ve ne kadar performans elde edildiği görülebilir.

Spor aktivitelerini tanımaya yönelik Eduardo V. ve arkadaşları yaptıkları çalışmada halter kaldırma aktivitesinin tespiti hedeflenmiştir. İvmeölçer, jiroskop ve pusula kullanılarak veri toplanılmıştır. Çalışma da %78,2 doğruluk elde edilmiştir.

Ermes ve arkadaşları tarafından yapılan çalışmada koşma, egzersiz yapma, yürüme, bisiklete binme, futbol oynama, kürek çekmek aktivitelerinin belirlenmesi hedeflenmiştir. İvmeölçer kullanılarak, belirlenen spor aktivitelerinde %89 doğruluk oranı elde edilmiştir.

Yürüme, koşma, bisiklete binme, kürek çekme, futbol oynama, uzanma, oturma, ayakta durma aktivitelerinin tespitine yönelik Miikka ve arkadaşları yaptıkları çalışmada aktivite verilerini toplamak için ivmeölçer verilerinden yararlanmışlardır. Alınan verilerin işleme aşamasından sonra %89 doğruluk elde edilmiştir.

Aktivite tanımada spor aktivitelerine yönelik çalışmalar artmaktadır. Ryan S. M. Ve arkadaşları beyzbol aktivitesi tespitine yönelik çalışma gerçekleştirmişlerdir. İlgili çalışmalarında ivmeölçer verilerinden yararlanılmıştır. Aktivite tanımada %90 doğruluk elde edilmiştir.

**Çizelge 2.2.** Spor aktivitelerine yönelik yapılan çalışmaların algılayıcı, öznelik, sınıflandırma ve performans belirlenmesine yönelik yapılan değerlendirmesi

Referans	Algılayıcı	Aktivite	Performans (doğruluk)
Eduardo ve arkadaşları	İvmeölçer, jiroskop ve pusula	Ağırlık kaldırma	%78,2
Amin ve arkadaşları	İvmeölçer, jiroskop	Tenis oynama, servis yapma	-
Ermes ve arkadaşları	İvmeölçer	Koşma, egzersiz yapma, yürüme, bisiklete binme, futbol oynama, kürek çekme	%89
Ryan ve arkadaşları	İvmeölçer, jiroskop	Beyzbol antrenmanı	%90

**Çizelge 2.2.** (devam)

Referans	Algılayıcı	Aktivite	Performans
Bussmann ve arkadaşları	İvmeölçer	Koşma, yürüme, oturmak, ayakta durmak, televizyon izlemek, bisiklete binmek, yemek yemek, okumak	%84
Jason ve arkadaşları	İvmeölçer, jiroskop	Kayakla akrobatik hareketler yapma	-
Miikka ve arkadaşları	İvmeölçer	Yürümek, koşmak, bisiklete binmek, kürek çekmek, futbol oynamak, uzanmak, oturmak, ayakta durmak	%89
Jonathan ve arkadaşları	İvmeölçer	Merdive inip çıkma, yürüme, ayakta durma, diş fırçalama	%90

### 2.3. İnşaat Aktiviteleri

Günlük hayattaki koşma, yürüme, araç kullanma gibi aktivite tanımlarının dışında inşaat alanında da aktivite tanıma çalışmaları yapılmaya başlanmıştır. İşçilerin inşaat alanındaki faaliyetlerinin yönetimi konusunda çok az araştırma bulunmaktadır. İşçilerin faaliyetlerini zamanında ve etkili bir şekilde analiz etmek ve izlemek için işçilerin üretim verimliliğinin izlenmesi ve değerlendirilmesinde önemlidir. Teknolojinin gelişmesiyle beraber inşaat sektöründe de aktivite tanıma çalışmaları yapılmaya başlanılmıştır. Çizelge 2.3'te inşaat aktivitelerini tanımaya yönelik çalışmalardan bahsedilmektedir.

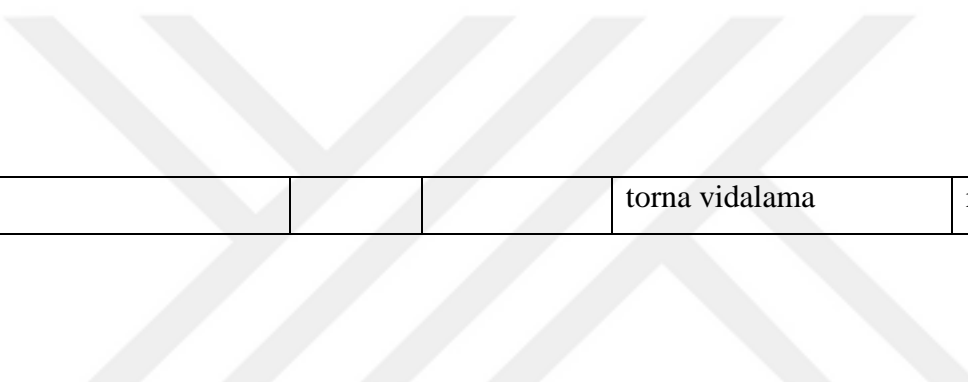
İnşaat aktivitelerin tespitine yönelik Mingyuan Z. ve arkadaşları yaptıkları çalışmada yürüme, ayakta durma, çömelme, alan temizleme, inşaat demiri bağlama aktivitelerini belirlemeyi hedeflemişlerdir. Aktivite verilerini toplarken cep telefonunun ivmeölçer verisinden yararlanılmıştır. CART sınıflandırma yöntemi kullanılarak %95,5 doğruluk elde edilmiştir.

Reza ve arkadaşları inşaat aktivitelerini tanımaya yönelik cep telefonunun ivmeölçer ve jiroskop verilerinden yararlanılmaktadır. Kepçenin yük yükleme, yük boşaltma hareket hali ve hareketsiz halleri aktivitelerinin tespitine yönelik çalışılmıştır. Toplanan verilere kNN, karar ağacı, sinir ağı, lojistik regresyon, DVM sınıflandırma yöntemleri uygulanarak %95 doğruluk oranı elde edilmiştir.

Reza ve arkadaşları başka bir çalışmalarında testere, el arabasına yük yükleme veya boşaltma, çekiçleme ve torna vidalama aktivitelerini belirleme hedeflenmiştir. Cep telefonunun bilek bandıyla bilek, dirsek, pazuya yerleştirilmiştir. Telefonun ivmeölçer verilerinden yararlanılarak toplanan veriler kNN, karar ağacı, sinir ağı, lojistik regresyon, DVM sınıflandırma yöntemlerinden geçirilerek %95 doğruluk elde edilmiştir.

**Çizelge 2.3.** İnşaat aktivitelerine yönelik yapılan çalışmaların algılayıcı, öznelilik, sınıflandırma ve performans belirlenmesine yönelik değerlendirmesi

Referans	Cihaz	Algılayıcı	Aktivite	Yöntem	Pozisyon	Performans (doğruluk)
Mingyuan ve arkadaşları	Telefon	İvmeölçer	Yürüme, ayakta durma, çömelme, alan temizleme, inşaat demiri bağlama	CART	-	%95,5
Reza ve arkadaşları	Telefon	İvmeölçer, jiroskop	Kepçenin yük yüklemesi, kepeğin yük boşaltılırken hareket hali ve hareketsiz hal	kNN, karar ağacı, yapay sinir ağı, lojistik regrasyon, DVM	-	%95
Nipun ve arkadaşları	Telefon	İvmeölçer, jiroskop	Taşıyıcı arabaya koli yükleme, taşıma indirme ve kaldırma	kNN	Akıllı telefonu kolun üst kısmına ve beline takarak	%94
Reza ve arkadaşları	Telefon	İvmeölçer, jiroskop	Testere, el arabasına yük yükleme veya boşaltma, çekiçleme ve	kNN, karar ağacı, yapay sinir ağı, lojistik	Bilek bandıyla bilek, dirsek, pazu	%95



			torna vidalama	regrasyon, DVM		
--	--	--	----------------	----------------	--	--

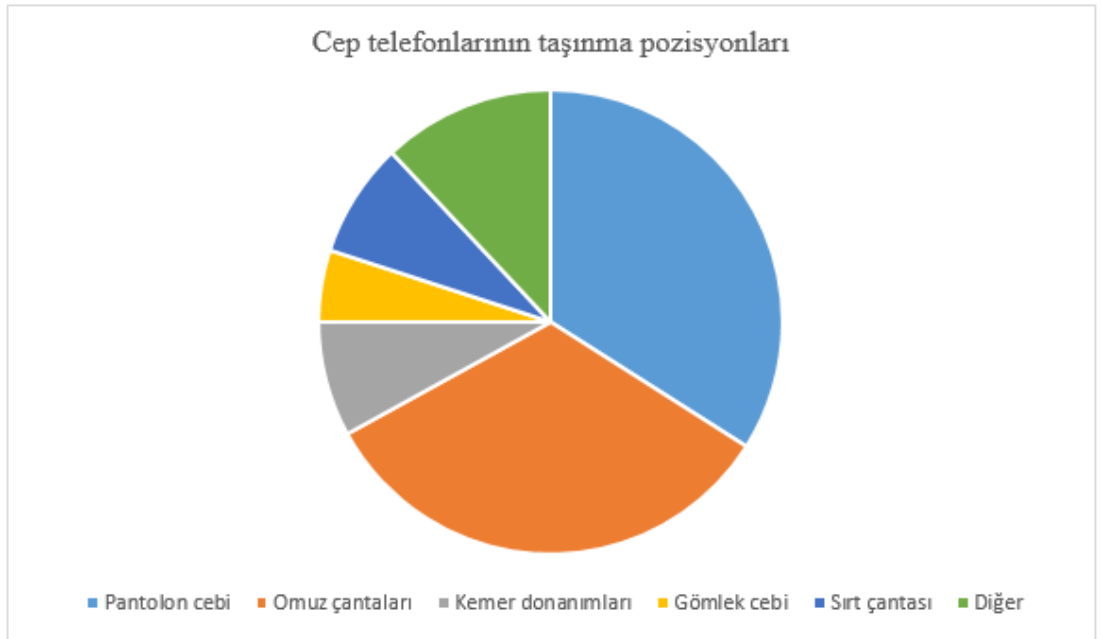
Literatürdeki çalışmalar incelendiğinde aktivite tanımada kayak aktivitesi için bir çalışma yapıldığı snowboard aktivitesi için ise uygulama yapılmadığı belirlenmiştir. Ayrıca aktivite tanımada inşaat aktivitelerinin testine yönelik çok fazla çalışma yapılmadığı da belirlenmiştir. İnşaat aktivitelerinin tespiti için mevcut çalışmalar da algılayıcı yapılan harekete göre vücudun farklı bölgelerine koyularak veri toplanmıştır. Bunun da günlük yaşantıda kullanılabilir bir durum olmadığı düşünülmektedir. Bu nedenle bu çalışmada belirtilen durumlar dikkate alınıp kayak ve snowboard verileri toplanmıştır. Veriler toplanılırken günlük yaşantıya daha uygun olan bileklik kullanılmıştır.



### 3. MATERYAL ve YÖNTEMLER

#### 3.1. Donanım Bileşenleri

İnşaat ve spor aktivitelerinin tespitinin yapılması için algılayıcı verilerinin toplanması gerekmektedir. Cep telefonları bu amaç için ilk akla gelecek cihazlardır. Ancak cep telefonlarının aktivite tanıma kullanımının çeşitli dezavantajları bulunmaktadır. İlk problem cep telefonlarının taşınma pozisyonunun değişkenliğidir. Cep telefonları Şekil 3.1’de görüldüğü gibi çok farklı pozisyonlarda taşınabilmektedir. Belirli bir taşınma şekline göre geliştirilen aktivite tanıma sisteminin farklı bir taşınma pozisyonunda performansı düşük olacaktır. Ayrıca en sık kullanılan pantolon cepi ve çanta gibi pozisyonlarda el ve kol hareketleri algılanamayacağından bu pozisyonlarda çalışan aktivite tanıma sistemleri, el ve kol hareketleri aracılığıyla birbirinden ayrılacak aktiviteleri ayırt etmekte zorluk çekecektir. Bu nedenlerle bu çalışmada veri toplamak için bileklik tercih edilmiştir.



**Şekil 3.1.** Günlük yaşamda akıllı cep telefon taşıma pozisyonları (Ichikawa *et al.* 2005)

Aktivite tanıma yapmak için plastik kutuya saat kordonu monte ederek bir bileklik oluşturulmuştur (Şekil 3.2). Verilerin toplanması için bileklik içerisine ivmeölçer ve pusula yerleştirilmiştir. Algılayıcılardan gelen değerleri almak için Photon geliştirme kartı, güç kaynağı olarak Li-Po batarya kullanılmıştır.



**Şekil 3.2.** Aktivite tanıma için yapılan bileklik ve kol saatine göre boyutunun gösterimi

Aktivite tanımada ilk olarak spor aktivitesi tanıma çalışması yapılmıştır. Belirlenen aktivitelerin (yürüme, koşma, araç kullanma, kayak yapma ve snowboard) verilerinin toplanması için ivmeölçerden yararlanılmıştır. Alınan veriler bulut destekli Photon geliştirme kartı vasıtasıyla sunucuya bağlanarak CSV uzantılı dosyaya kaydedilmektedir. Aynı işlem ayrıca pusula algılayıcısı eklenilerek inşaat aktivitelerini belirlemek için de tekrar yapılmıştır.

### **3.1.1. Particle photon geliştirme kartı**


Teknolojinin hızla gelişmesiyle akıllı sistemler hayatımızın her alanında yer almaya başlamıştır. Nesnelerin interneti olarak nitelendirilen akıllı sistemler kısaca nesnelerin

birbirleriyle haberleşmesi anlamına gelmektedir (Ercan *et al.* 2016). Nesnelerin birbirleriyle haberleşebilmesi için çeşitli geliştirme kartları kullanılmaktadır.

Bu tez çalışmasında bulut destekli Şekil 3.3'te görülen Photon geliştirme kartı kullanılmıştır. Kablolu ve kablosuz programlanabilen açık kaynak kodlu ve bulut destekli Particle Core Photon geliştirme kartı algılayıcıların verilerinin alınıp bulut desteği ile uzak sunucuya kaydedilmesini sağlamaktadır.

Modül özellikleri;

- ✚ Açık kaynak kodlu
- ✚ Arduino uyumlu
- ✚ Spark Cloud desteği
- ✚ ARM Cortex M3 İşlemci
- ✚ Flash hafıza(128KB), RAM(20KB)
- ✚ Wi-Fi modülü
- ✚ Dahili EEPROM
- ✚ 2MB harici flash bellek
- ✚ 90 metreye kadar geniş Wi-Fi ağı



**Şekil 3.3.** Aktivite tanımada kullanılan Photon geliştirme kartı ve bileşenleri

### 3.1.2. HMC5883L pusula

Bu tez çalışmasında HMC5883L pusula algılayıcısı kullanılmıştır (Şekil 3.4). Çevredeki manyetik değerlerin etkisi alınarak doğruluk oranının artırılması hedeflenmiştir.

Modül özellikleri;

- ✚ 3-5V giriş
- ✚ Dijital I2C Haberleşme Protokolü




**Şekil 3.4.** Aktivite tanıma kullanılan X, Y, Z üç eksende manyetik alan ölçümü yapabilen HMC5883L pusula

### 3.1.3. ADXL345 ivmeölçer

Bu tez çalışmasında ADXL345 ivmeölçer algılayıcısı kullanılmıştır (Şekil 3.5). Belirlenen aktivite hareketlerinin x, y, z eksen değerleri bu algılayıcı ile alınarak aktivitenin belirlenmesi amaçlanmıştır.

Modül özellikleri;

- 3-5V giriş
- Düşük güç tüketimi(40uA)



**Şekil 3.5.** Aktivite tanıma kullanılan X, Y, Z Z üç eksen koordinat alan ADXL345 algılayıcı

### 3.1.4. Li-Po batarya

Kimyasal tepkime sonucu ortaya çıkan enerjiyi aktararak elektrik enerjisine dönüştürerek 3,7V enerji sağlamaktadır (Şekil 3.6).

Batarya özellikleri;

- Voltaj: 3,7V
- Kapasite: 950 mAh
- 25C (50C anlık, maksimum 10sn) sıcaklık
- Ağırlık: 217gr
- Boyutları: 53x30x11mm

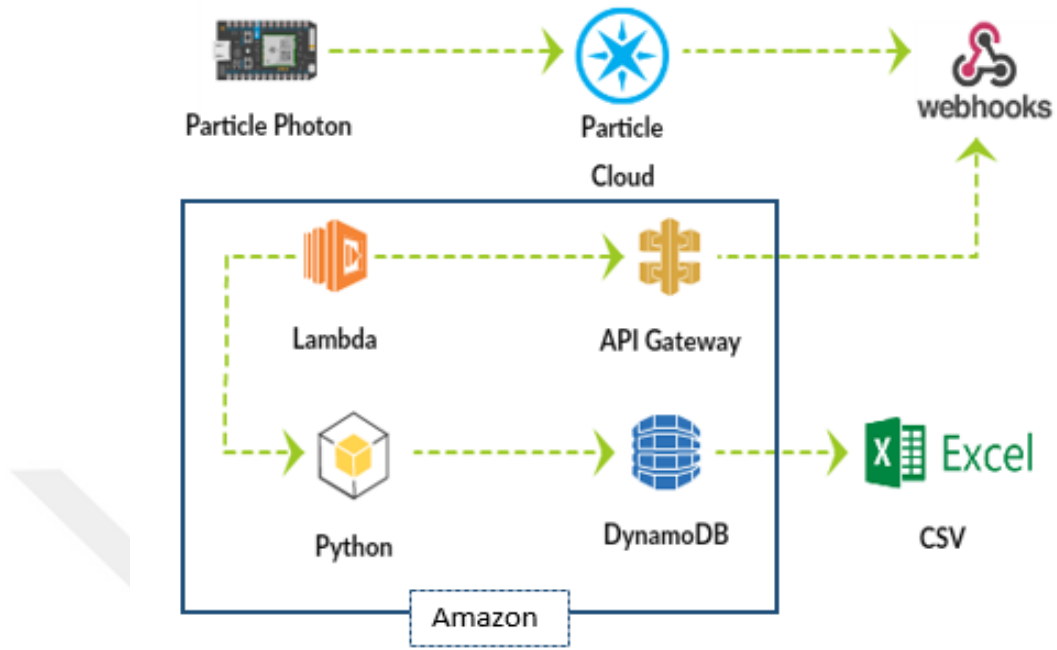


**Şekil 3.6.** Aktivite tanıma da kullanılan Li-Po batarya

### 3.2. Sunucu Uygulaması

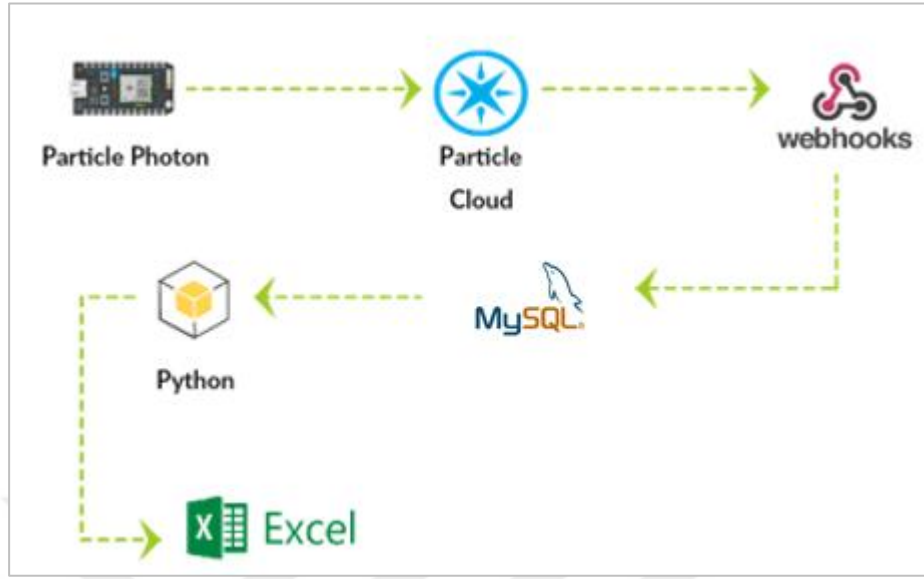
Aktivitelerin belirlenmesi için bileklik içerisine ivmeölçer, pusula, Photon geliştirme kartı ve batarya yerleştirilmiştir. Algılayıcılardan alınan üç eksenli veriler Photon geliştirme kartı ile alınarak CSV uzantılı dosyaya kaydedilmektedir.

Çalışmada ilk olarak spor aktivitelerini belirlemek için Şekil 3.7’de gösterildiği gibi bir yapı kullanılmıştır. Bu yapıda ivmeölçerden alınan veriler Photon geliştirme kartı tarafından bulut ortamına aktarılmaktadır. C dili ile yazılmış Photon Particle CLI kütüphanesi kullanılmıştır. Şekil 3.7’de görüldüğü üzere, Bulut ortamına aktarılan veriler Webhook servisi ile her 6 saniyede bir Amazon API Gateway servisine aktarılmıştır. Amazon API Gateway servisi ise Amazon DynamoDB veri tabanına verileri yazmamız için Amazon Lambda servisinde tanımlanmış fonksiyonu tetiklemektedir. Amazon Lambda servisindeki fonksiyon Python programlama dilinde yazılmıştır.



**Şekil 3.7.** Spor aktivitelerinin belirlenmesi için verilerin ivmeölçerden alınıp CSV dosyasına yazılmasına kadar araç süreçlerin gösterimi

Spor aktivitelerini belirlerken Amazon AWS servisleri ve DynamoDB de tecrübe edinmek için Şekil 3.7’de gösterilen yapı kullanılmıştır. Fakat işlem adımlarının fazla olmasından dolayı inşaat aktivite verilerini toplarken Şekil 3.8’deki gibi işlem adımları uygulanmıştır.



**Şekil 3.8.** İnşaat aktivitelerinin belirlenmesi için verilerin ivmeölçer ve pusuladan alınıp CSV dosyasına yazılmasına kadar süreçlerin gösterimi

### 3.3. Aktiviteler

Bu tez çalışmasında, sırasıyla spor ve inşaat aktivitelerini içeren iki ayrı çalışma yapılmıştır. Spor aktivitelerini içeren çalışmada kullanılan aktiviteler aşağıda listelenmiştir (Şekil 3.9):

- Yürüme
- Koşma
- Araç kullanma
- Kayak yapma
- Snowboard



**Şekil 3.9.** Aktivite tanıma için yapılan koşma, yürüme, araç kullanma, kayak ve snowboard gibi spor aktiviteleri gösterimi

İnşaat aktivitelerini içeren çalışmada kullanılan aktiviteler aşağıda listelenmiştir (Şekil 3.10):

- Matkapla delme
- Duvar boyama
- Testere ile kesme
- Duy vidalama
- Musluk sıkma
- Çekiçle çakma



**Şekil 3.10.** İnşaat aktivitelerini tanıma için matkapla delme, çekiçle çakma, testere ile kesme, musluk sıkma, vidalama ve duvar boyama gibi yapılan inşaat aktiviteleri gösterimi

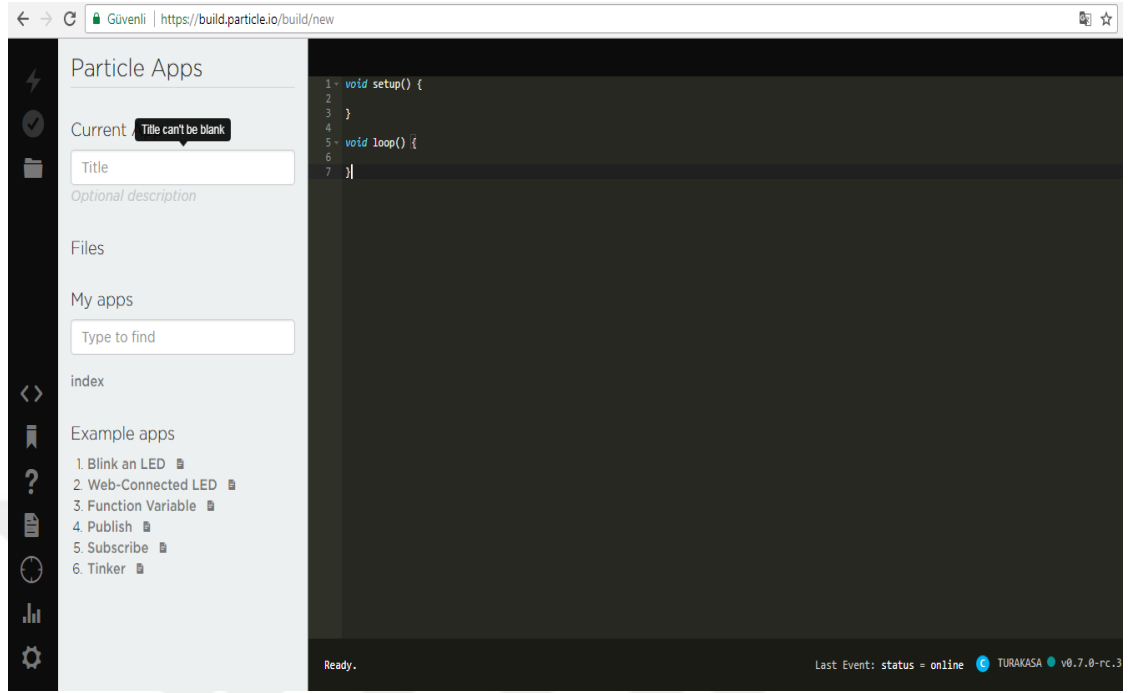
#### 3.4. Veriler ve Sınıflandırma

Algılayıcılarla Photon geliştirme kartı arasından iletişimi sağlamak için ilk olarak Particle web sitesini ziyaret ederek yeni bir üyelik hesabı oluşturulmalıdır.

Particle web hesabına giriş yaptıktan sonra Spark Cloud için Çizelge 3.1'deki menülerinden yararlanılarak ilgili kod akışı sağlanmaktadır (Şekil 3.11).

**Çizelge 3.1.** Particle web sayfası Spark Cloud menüleri

İkon	Açıklama
	Yazılım kodlarımızı cihaza aktarmak
	Yazılım kodlarını doğrulamak
	Yazılım kodlarını “Web IDE” üzerinde kayıtlı tutmak için kaydeder
	Oluşturulan dosyayı görüntülemek ve programlamak
	Particle kütüphanesi “Github” üzerinden paylaşılan örnek çalışmalar
	Cihazın ışıklarının hangi durum ne anlama gelir hızlıca özetlendiği alan
	Particle dokümanlarının yer aldığı alan. Sizi otomatik olarak web sayfasına yönlendirir
	Cihazın bilgisi ve sinyal göndermek ve firmware sürümlerini güncellemek ve değiştirmek
	Cihazın komut satırı ve yaptığı eylemlerin raporunu veren alan
	Cihaz belleğini temizleme, oturum kapatma ve erişim kodunu değiştirme işlemi sağlayan alan



**Şekil 3.11.** Photon Spark Core cihazlar için programlama arayüzünün (Spark Cloud) ekran görüntüsü

Aktivitelerin toplanması için plastik kutu içerisine algılayıcılar, Photon Particle ve batarya Şekil 3.12 (a)'daki gibi yerleştirilmektedir. Ardından, kutu kapatılıp, saat kordonu aracılığıyla bileğe sabitlenerek Şekil 3.12 (b)'de gösterildiği şekilde kullanılmaktadır.

Algılayıcılar, Photon Particle ve batarya Şekil 3.12'deki gibi bileklik içerisine yerleştirilerek bileğe takılmıştır.



(a)



(b)

**Şekil 3.12.** a)Aktivite tanıma için kullanılan bilekliğin kapağı açık görüntüsü b) Aktivite tanıma için kullanılan bilekliğin kapağı kapalıyken ve bileğe sabitlenmişken görüntüsü



**Şekil 3.13.** Çalışmada kullanılan aktivite tanıma süreci

Aktivite tanıma için inşaat aktivitesi olarak matkapla delme, vidalama, çekiçle delme, boyama, testere ve musluk sıkma aktiviteleri belirlenmiştir. Belirlenen 6 aktivitenin her birinden 10.000 veri alınarak toplamda 60.000 veri elde edilmiştir. Ayrıca spor aktivitesi olarak yürüme, koşma, araç kullanma, kayak yapma ve snowboard aktiviteleri belirlenmiştir. Spor verileri 1 bayan 2 erkek tarafından toplanmıştır. Kayak ve snowboard aktiviteleri için 6 yıllık deneyimli amatör sporcuların aktivite esnasında verileri alınmıştır.

Verilerin işlenmesinden önce Şekil 3.14'te gösterildiği gibi veri ön işleme aşaması yapılmaktadır. Veri ön işleme için normalleştirme kullanılmaktadır. Ham verilerin [0,1] aralığın da ölçeklendiren normalleştirme formül aşağıda verilmiştir.

$$X_{yeni} = (X - X_{enküçük}) / (X_{enbüyük} - X_{enküçük}) \quad (3.1)$$

Yukarıdaki formül 60.000 inşaat verisi ve 10.000 spor verisine uygulanılarak normalleştirme yapılmıştır.

Veri toplama için geliştirmiş olduğumuz sistemin toplamış olduğu verilerden aşağıdaki öznitelik değerlerini kullanarak veri kümesi oluşturulmuştur. Her aktivite için 10.000 veri toplanılarak toplamda 60.000 veri elde edilmiştir. Elde edilen ham veriler normalleştirme ön işleme aşamasından sonra ortalama, standart sapma, kolerasyon gibi öznitelik değerleri çıkarılmıştır. Her algılayıcının x, y, z koordinat değerlerine göre öznitelikler çıkarılmıştır. 7 özniteliğin ivmeölçer ve pusulanın x, y, z koordinat değerlerine göre kırk dört öznitelik elde edilmiştir.

Çalışmada öznitelik hesaplamada kullanılan formüller (Çizelge 3.3);

i: başlangıç değeri

$x_i$ : x değerleri için ilk değer

$y_i$ : y değerleri için ilk değer

$z_i$ : z değerleri için ilk değeri

N: toplam değeri sayısını temsil etmektedir.

Çizelge 3.4’de ham verilerin belirlenen öznitelikleri çıkarılarak oluşturulan öznitelik veri kümesine dair örnek görülmektedir.

**Çizelge 3.2.** Aktivite tanımada kullanılan öznelikler ve formülleri


Algılayıcı	Özellik	Sütun adları	Açıklama	Formül	Özellik sayısı
İvmeölçer, Pusula	Ortalama	ort_ivme_x, ort_ivme_y, ort_ivme_zort_pusula_x, ort_pusula_y, ort_pusula_z	Her algılayıcının üç eksen için ortalama değeridir.	$\sum_{i=1}^N x_i / N$	6
	Ortalama Büyüklük	ort_büyük_ivme,ort_büyük_pusula	Her algılayıcının her eksendeki eğerlerinin karelerinin toplamının karekökünün ortalaması	$\sum_{i=1}^N \sqrt{x_i^2 + y_i^2 + z_i^2} / N$	2
	En Küçük Değer	enkucuk_ivme_x enkucuk_ivme_y enkucuk_ivme_z,enkucuk_pusula_x, enkucuk_pusula_y enkucuk_pusula_z	Her algılayıcının her eksendeki en küçük ivme değeri	$\min(x), \min(y), \min(z)$	6
	En Büyük Değer	enbuyuk_ivme_x , enbuyuk_ivme_y enbuyuk_ivme_z, enbuyuk_pusula_x, enbuyuk_pusula_y enbuyuk_pusula_z	Her algılayıcının her eksendeki en büyük ivme değeri	$\max(x), \max(y), \max(z)$	6
	Standart Sapma	sapma_ivme_x , sapma_ivme_y, sapma_ivme_z, sapma_pusula_x , sapma_pusula_y, sapma_pusula_z	Her algılayıcının tüm eksendeki ivme değeri ile ortalama değer arasındaki farkın karelerinin ortalaması	$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$	6
	Mutlak Ortalama Fark	mutlak_ivme_x, mutlak_ivme_y mutlak_ivme_z, mutlak_pusula_x, mutlak_pusula_y, mutlak_pusula_z	Her eksendeki ivme değeri ile ortalama değer arasındaki mutlak farkın ortalaması	$\frac{1}{N} \sum_{i=1}^N  x_i - \bar{x} $	6
	Zero Cross	zero_ivme_x, zero_ivme_y , zero_ivme_z, zero_pusula_x , zero_pusula_y , zero_pusula_z	Her eksendeki ivme işaretindeki değişim sayısı	-	6
	Korelasyon	kor_ivme_xy, kor_ivme_xz, kor_ivme_yz, kor_ivme_xy, kor_ivme_xz , kor_ivme_yz	Her eksenin birbiri arasındaki doğrusal bağımlılığının kuvveti	$\frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}$	6

**Çizelge 3.3.** Ham veriye öznitelik dönüşümü uygulandıktan sonra elde edilen veri kümesinden örnek olarak alınan değerler

ort_ivme_ x	ort_ivme_ y	ort_ivme_z	ort_pusula _x	ort_pusula _y	ort_pusula_ z	....	enbuyuk_ivme _x	enbuyuk_ivme _y	...	aktivite
0.500332	0.499325	0.000344	0.67891	0.320831	0.000259		0.997987	0.00183		Boyama
0.484535	0.027406	0.488058	0.02877	0.967508	0.003722		0.997987	0.999771		Boyama
0.500985	0.498188	0.000827	0.684623	0.31522	0.000157		0.993042	0.001648		Boyama
0.500985	0.498188	0.000827	0.684623	0.31522	0.000157		0.992554	0.001648		Boyama
0.500985	0.498188	0.000827	0.686502	0.313351	0.000147		0.992554	0.001648		Boyama
0.500985	0.498188	0.000827	0.686513	0.313351	0.000136		0.992554	0.001648		Boyama
0.500965	0.498177	0.000858	0.686516	0.313348	0.000136		0.992554	0.001709		Boyama
0.500965	0.498177	0.000858	0.692174	0.307689	0.000137		0.992554	0.001709		Boyama
0.500965	0.498177	0.000858	0.692162	0.307679	0.000159		0.992554	0.001709		Boyama
0.500965	0.498177	0.000858	0.694072	0.305769	0.000159		0.992554	0.001709		Boyama
0.001979	0.98333	0.014691	0.333319	0.33334	0.33334		0.998898	0.014924		Matkapla delme
0.002306	0.987626	0.010067	0.333314	0.333356	0.33333		0.998898	0.010175		Matkapla delme
0.002306	0.987626	0.010067	0.333306	0.333373	0.333322		0.998195	0.010175		Matkapla delme
0.002306	0.987626	0.010067	0.333328	0.333369	0.333303		0.998195	0.010175		Matkapla delme
0.002306	0.987626	0.010067	0.333328	0.333385	0.333288		0.998195	0.010175		Matkapla delme
0.002306	0.987626	0.010067	0.333333	0.333379	0.333288		0.998195	0.010175		Matkapla delme
0.002306	0.987626	0.010067	0.333341	0.333367	0.333291		0.998195	0.010175		Matkapla delme
0.002241	0.986745	0.011015	0.333345	0.333366	0.333289		0.998195	0.011144		Matkapla delme
0.002241	0.986745	0.011015	0.333348	0.333364	0.333288		0.998338	0.011144		Matkapla delme
0.002241	0.986745	0.011015	0.333338	0.333344	0.333318		0.998338	0.011144		Matkapla delme
0.002241	0.986745	0.011015	0.333343	0.333349	0.333308		0.998338	0.011144		Matkapla delme
0.002241	0.986745	0.011015	0.33335	0.33333	0.33332		0.998338	0.011144		Matkapla delme
0.002241	0.986745	0.011015	0.333345	0.333351	0.333305		0.998338	0.011144		Matkapla delme
0.001934	0.982437	0.015629	0.333343	0.333344	0.333313		0.998338	0.015893		Matkapla delme

### k-En Yakın Komşu Algoritması (kNN)

kNN algoritmaları, T. M. Cover ve P. E. Hart tarafından 1967 yılında önerilmiştir (Cover T.M. et all.). Sınıflandırma yöntemi hem sınıflandırma hem de regresyon tahmini problemleri için kullanılmaktadır. Örnek veri kümesine katılacak olan yeni verinin, mevcut verilere göre uzaklığı hesaplanıp, k sayıda yakın komşuluğuna bakılır (Şekil 3.14).



**Şekil 3.14.** kNN sınıflandırma yönteminde  $k=3$  değeri için uzaklık kullanarak bilinmeyen bir durumu sınıflandırmak (Anonymous 2012)


Uzaklık hesapları için genelde 3 tip uzaklık fonksiyonu kullanılmaktadır:

- “Euclidean” Uzaklık
- “Manhattan” Uzaklık
- “Minkowski” Uzaklığı’dır.

### Destek Vektör Makineleri (DVM)


Destek Vektör Makineleri, belirli bir gruba (veya kategoriye) ait vektörler ve kendisine ait olmayan vektörler arasındaki en iyi karar çizgisini belirleyen bir algoritmadır. Karar

çizgisi, farklı sınıf üyeliğine sahip bir nesne kümesi arasında ayrılan çizgidir. Şekil 3.15'te görüldüğü gibi nesnelere ya mavi ya da kırmızı sınıfa aittir. Karar çizgisi, solundaki tüm nesnelere mavi olduğu ve sağdaki tüm nesnelere kırmızı olduğu bir sınırı tanımlar.



**Şekil 3.15.** DVM sınıflandırma yönteminde karar çizgisi ile verileri kümeleme

Çoğu veri, optimal bir ayırım yapmak için o kadar basit değildir. Dolayısıyla sınıflandırma için daha karmaşık yapılara ihtiyaç duyulur (Şekil 3.16). Örnek olarak Şekil 3.15'te gösterilen mavi ve kırmızı nesnelere tam ayırımın bir eğri gerektireceği açıktır. Farklı sınıf üyeliğindeki nesnelere ayırt etmek için ayrı çizgiler çizmeye dayanan sınıflandırma görevleri, hiper düzlem sınıflandırıcıları olarak bilinir.



**Şekil 3.16.** DVM sınıflandırma yönteminde karmaşık yapıdaki nesnelerin tam olarak ayrılması

### Näive Bayes (NB)

Näive Bayes, Bayes teoreminden esinlenen şartlı olarak bağımsız olan basit bir varsayım ile oluşan olasılıksal bir sınıflandırıcıdır.

$$P(X|C_i) = P(x_1|C_i) * P(x_2|C_i) * \dots * P(x_n|C_i)$$

$P(x | c)$ , verilen sınıfın gerçekleşme olasılığıdır.

Näive Bayes sınıflandırma yöntemi çoğu durumda karmaşık durumlar için iyi sonuçlar verir. Diğer birçok sınıflandırıcı için kullanılan pahalı yinelemeli yaklaşımda bulunmadığı için daha büyük veri kümelerine kolayca ölçeklenebilir.

**Rastgele Orman (RO)**

Rastgele Orman algoritması, denetimli bir sınıflandırma ve regresyon algoritmasıdır. Adından da anlaşılacağı gibi bu algoritma rastgele ağaçlardan oluşan bir ormandan oluşturmaktadır.

Genel olarak, ormandaki ağaçlar ne kadar fazlaysa, orman o kadar sağlam görünür. Dolayısıyla, ormandaki ağaç sayısı arttıkça, sonuçların doğruluğu da artar.



#### 4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu tez çalışması daha önce belirtildiği gibi spor ve inşaat aktiviteleri olarak iki alt çalışmadan oluşmaktadır. İlk olarak spor aktiviteleri belirlenerek aktivite tanıma hedeflenmiştir. Koşma, yürüme, araç kullanma, kayak yapma ve snowboard aktivitelerinin tespiti üzerine çalışılmıştır. Aktivitelerden toplamda 10.000 veri elde edilmiştir. Ham veriler toplanılarak öznitelikleri çıkarılmıştır. Öznitelikleri çıkarılan veriler sınıflandırma yöntemlerinde geçirilerek doğruluk analizi yapılmıştır.

Diğer çalışmada ise aktivite olarak inşaat sektöründe temel işlemler olan maktapla delme, testere ile kesme, musluk sıkma, vidalama ve çekiçle çakma aktiviteleri kullanılmıştır. Bu aktivitelerden ise toplamda 60.000 veri elde edilmiştir. Toplanan veriler normalleştirme ve öznitelik çıkarma işlemlerinden geçirildikten sonra elde edilen öznitelik veri kümesine sınıflandırma yöntemleri uygulanmıştır.

##### 4.1. Spor Aktiviteleri

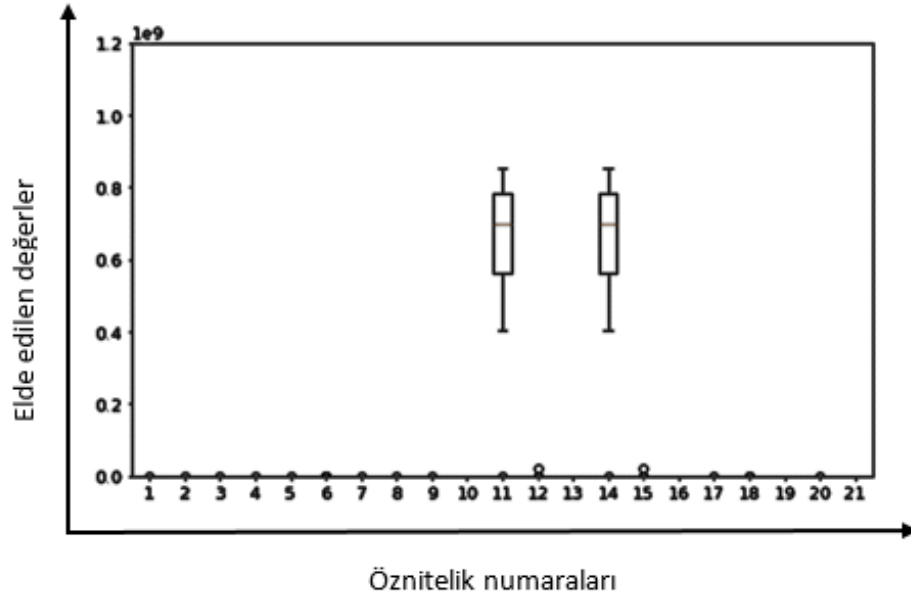
Bu bölümde, spor aktivitesine yönelik yapılan çalışmanın sonuçları açıklanacaktır. Bu çalışma için seçilen aktiviteler yürüme, koşma, snowboard, araç kullanma ve kayak yapma aktiviteleridir. Çalışmada veriler 3 kişi tarafından toplanılmıştır. Her bir aktiviteden iki bin veri toplanılarak toplamda 10.000 veri elde edilmiştir. Toplanan veriler kNN, DVM, RO ve NB sınıflandırma yöntemlerinde geçirilerek aktivite tanımadaki doğruluk oranı belirlenmiştir. Aktivite tanımadaki kullanılan sınıflandırma yöntemleri ve aktivite bazlı doğruluk yüzdeleri Çizelge 4.1’de gösterilmiştir. Bu bölümde sunulan sonuçlar daha önce bir konferans bildirisi olarak yayınlanmıştır (Kaytaran *et al.*).

**Çizelge 4.1.** Spor aktiviteleri olarak yapılan koşma, yürüme, araç kullanma, kayak ve snowboard aktivitelerinin sınıflandırma yöntemlerine göre elde edilen doğruluk yüzdeleri


Aktivite	SVM	NB	RO	kNN
Yürüme	%89,7	%95,9	%97,5	%96,1
Koşma	%90,1	%97,9	%98,6	%98,2
Snowbord	%85,9	%91,4	%93,7	%93,9
Kayak	%88,3	%95,8	%96,7	%96,3
Araba Sürme	%91,8	%96,3	%98,7	%97,9

Çizelge 4.1’de koşma, yürüme, araç kullanma, kayak ve snowboard aktivitelerinin SVM, NB, RO ve kNN sınıflandırma yöntemine göre doğruluk yüzdeleri verilmiştir. Kullanılan sınıflandırma yöntemleri içerisinde en iyi sonucu veren yöntem RO olup %98,7 doğruluk yüzdesi ile araç kullanma aktivitesi için elde edilmiştir.

Çalışmada kullanılan öznitelik değerleri incelendiğinde, sınıflandırmaya yüksek oranda katkı sağlayan özniteliklerin 10, 11, 12, 13, 14 ve 15 olduğu görülmektedir. Bu kısımlar standart sapma ve mutlak ortalama fark değerlerini (x, y ve z değerleri için) temsil etmektedir. Diğer öznitelikler sıfıra çok yakın değerler vermektedir. Bu aralıktaki standart sapma ve mutlak ortalama fark öznitelikleri ise sıfırdan çok yüksek değerler olduğu görülmektedir (Şekil 4.1).



(a)



(b)

**Şekil 4.1.** Kayak (a) ve Snowboard (b) aktivitelerinin öznitelik dağılımı

Şekil 4.1 (a)'da kayak verilerinin öznitelik dağılımı, Şekil 4.1 (b) de ise snowboard verilerinin öznitelik dağılımı gösterilmektedir. Şekil 4.1'de görüldüğü gibi snowboard ve kayak sonuçları birbirinden net bir şekilde ayrılmaktadır. Şekil 4.1'e göre snowboard aktivitesinin öznitelik değerleri kayak aktivitesinin öznitelik değerine göre daha yüksek olduğu gözlemlenmektedir. Bu durumun nedeni olarak, snowboard aktivitesinin kayma

sırasında vücut dengesinin sağlanması için daha çok vücut hareketi yapması (slalom) düşünülmektedir.

#### 4.2. İnşaat Aktiviteleri

Çalışmanın ikinci kısmı matkapla delme, boyama, vidalama, testere ile kesme, musluk sıkma ve çekiçle çakma gibi inşaat aktiviteleri tespit edilmeye çalışılmaktadır. Bu çalışmada veriler toplanırken matkapla delme ve çekiçle çakma aktiviteleri için otopark alanı diğer aktiviteler için ise ev ortamı kullanılmıştır. Her bir aktivite için 10.000 veri toplanmış toplamda 60.000 veri elde edilmiştir. Toplanan veriler kNN, DVM, RO ve NB sınıflandırma yöntemlerinde geçirilerek aktivite tanımada doğruluk oranı belirlenmiştir. Aktivite tanımada kullanılan sınıflandırma yöntemleri ve aktivite bazlı doğruluk yüzdeleri Çizelge 4.2’de gösterilmiştir.

**Çizelge 4.2.** İnşaat aktivitelerinden matkapla delme, boyama, vidalama, testere ile kesme, musluk sıkma ve çekiçle çakma için sınıflandırma yöntemlerine göre elde edilen doğruluk yüzdeleri

Aktivite	SVM	NB	RO	kNN
<b>Makapla delme</b>	%86,2	%74,5	%97,5	%96,2
<b>Boyama</b>	%92,3	%87,2	%95,6	%95,1
<b>Testere ile kesme</b>	%91,1	%73,0	%97,3	%96,8
<b>Vidalama</b>	%96,7	%72,3	<b>%99,7</b>	%98,6
<b>Musluk sıkma</b>	%88,3	%78,8	%92,7	%91,8
<b>Çekiçle delme</b>	%96,2	%83,3	%99,3	%97,3

Çizelge 4.2’de matkapla delme, boyama, vidalama, testere ile kesme, musluk sıkma ve çekiçle çakma aktiviteleri için RO, NB, DVM ve kNN sınıflandırma yöntemi doğruluk yüzdeleri verilmiştir. Kullanılan sınıflandırma yöntemleri içerisinde en iyi sonuç RO yöntemi olup %99,7 doğruluk yüzdesi ile vidalama için elde edilmiştir.


İnşaat aktiviteleri tanımlanırken ivmeölçer ve manyetik algılayıcılardan yararlanılmıştır. Çizelge 4.3 incelendiğinde ivmeölçerden alınan verilerin doğruluk oranında en iyi sonucu veren yöntemin %98 ile RO olduğu görülmektedir. İvmeölçerden alınan verilere göre elde edilen doğruluk oranına pusuladan alınan verilerin etkisi incelenmek istenmiştir. Sınıflandırma sonucunda Çizelge 4.3'teki gibi sonuçlar elde edilmiştir. Sadece ivmeölçer kullanılarak inşaat verileri toplandığında en iyi sonuç %98 doğruluk oranı ile RO sınıflandırma yönteminden alındığı belirlenmiştir. İvmeölçer verilerinin yanına pusuladan alınan veriler eklenilerek analiz edildiğinde en iyi sonuç %99 doğruluk oranı ile RO sınıflandırma yönteminden elde edilmiştir. Burada ivmeölçer algılayıcısından yüksek doğruluk oranı elde edildiği için pusula algılayıcısının etkisi yaklaşık %1 oranında olmuştur. Etki oranının az olmasının nedeninin ivmeölçerden elde ettiğimiz doğruluk oranının zaten çok yüksek bir değer olması olduğu düşünülmektedir.

**Çizelge 4.3.** Aktivite tanımada kullanılan ivmeölçer ve pusula verilerine göre sınıflandırma sonuçları

	İvmeölçer	İvmeölçer + Pusula
kNN	%97	%98
SVM	%74	%79
RO	%98	%99
NB	%73	%75

Sınıflandırma yöntemlerinin sonuçları, parametrelerinin değerlerine göre değişmektedir. kNN algoritmasını k değerindeki değişim etkilemektedir. En iyi sonucu bulmak için yaptığımız testler ve diğer akademik çalışmalarda kullanılan değer dikkate alınarak k=1 değeri için verdiği belirlenmiştir (Özger *et al.* 2013).

kNN algoritması k parametresi değişimine göre elde edilen doğruluk oranları Şekil 4.3'te gösterilmektedir.



**Şekil 4.3.** kNN algoritmasının k değerine göre değişimi

Kullanılan sınıflandırma yöntemlerinin parametrelerinde yer alan doğruluk değeri de sonucu etkilemektedir. Performans ölçütü olarak doğruluk oranı, kesinlik, duyarlılık ve F-ölçütü kullanılmaktadır. Performans ölçütleri kullanılarak kNN, SVM, RO ve NB sınıflandırma yöntemlerindeki doğruluk oranları Çizelge 4.4’te gösterilmektedir.

**Çizelge 4.4.** kNN, SVM, RO ve NB sınıflandırma yöntemlerinin performans ölçütlerine göre doğruluk oranındaki değişim

	Doğruluk	F1 ölçütü	Kesinlik	Duyarlılık
kNN	%98	%98	%98	%98
SVM	%79	%79	%81	%83
RO	%99	%99	%99	%99
NB	%75	%74	%80	%80

Yine kNN sınıflandırma yöntemi için çapraz doğrulama değerindeki değişim doğruluk oranını etkilemektedir. Çapraz doğrulama, makine öğrenmesi modelinde yapılan testin hatasını daha iyi tahmin edebilmek için model seçiminde kullanılan bir tekniktir. Çalışmada çapraz doğrulama 5, 10 ve 20 değerlerine göre incelenmiştir (Çizelge 4.5). Bu çalışmada çapraz doğrulama değeri olarak 10 tercih edilmiştir.

**Çizelge 4.5.** kNN sınıflandırma yönteminde çapraz doğrulamının doğruluk oranına etkisi

Çapraz Doğrulama Değeri	Doğruluk Oranı
5	0.980
10	0.981
50	0.983

Sınıflandırma yöntemlerinde RO yöntemi çalışma mantığı gereği iterasyon sayısı önem arz etmektedir. İterasyon sayısındaki değişime göre doğruluk oranı analiz edildiğinde Çizelge 4.6'daki gibi sonuçlar elde edilmektedir. Çalışmada iterasyon sayısı olarak 100 değeri tercih edilmektedir.

**Çizelge 4.6.** RO sınıflandırma yönteminde iterasyon sayısının doğruluk oranına etkisi

İterasyon Sayısı	Doğruluk Oranı
10	0.9969
100	0.9973
200	0.9977

Çalışmada ivmeölçer ve pusula birlikte kullanılarak inşaat aktivitelerine ait veriler elde edilmiştir. Bu algılayıcılardan alınan verilerin kullanılan yöntemlere göre elde edilen karmaşıklık matrisleri Çizelge 4.7-5.10'da gösterilmektedir. Karmaşıklık matrislerinde Tes; testere, Mus; musluk sıkma, Vid; vidalama, Boy; boyama, Mat; matkap, Çek; çekiçle çakma eylemini göstermektedir.

Sınıflandırma yöntemlerine göre karmaşıklık matrisi tablosu incelendiğinde musluk sıkma ve vidalama aktivitesi benzer ekseninde hareket ettiği için birbiriyle karıştırılmaktadır. Yine çalışmada matkapla delme ve çekiç aktivitesi diğer aktivitelere göre benzer yönde hareket ettiği için karıştırılmaktadır.

**Çizelge 4.7.** Aktivite tanımada kullanılan NB yönteminin karmaşıklık matrisi

<i>NB</i>	<i>Tes</i>	<i>Mus</i>	<i>Vid</i>	<i>Boy</i>	<i>Mat</i>	<i>Çek</i>
<i>Tes</i>	223	0	0	0	0	1
<i>Mus</i>	0	80	2	1	1	0
<i>Vid</i>	0	14	71	0	1	1
<i>Boy</i>	0	0	0	224	0	0
<i>Mat</i>	0	0	0	2	152	0
<i>Çek</i>	0	0	0	0	10	125

**Çizelge 4.8.** Aktivite tanımada kNN yönteminin karmaşıklık matrisi

<i>kNN</i>	<i>Tes</i>	<i>Mus</i>	<i>Vid</i>	<i>Boy</i>	<i>Mat</i>	<i>Çek</i>
<i>Tes</i>	214	0	0	0	0	0
<i>Mus</i>	0	174	1	2	1	1
<i>Vid</i>	0	8	210	1	0	0
<i>Boy</i>	0	1	0	226	0	0
<i>Mat</i>	1	0	0	1	198	0
<i>Çek</i>	0	0	0	0	1	172

**Çizelge 4.9.** Aktivite tanımada RO yönteminin karmaşıklık matrisi

<i>RO</i>	<i>Tes</i>	<i>Mus</i>	<i>Vid</i>	<i>Boy</i>	<i>Mat</i>	<i>Çek</i>
<i>Tes</i>	226	1	0	0	0	0
<i>Mus</i>	0	201	0	0	0	0
<i>Vid</i>	0	1	227	0	0	0
<i>Boy</i>	0	1	0	228	0	0
<i>Mat</i>	1	0	1	0	196	0
<i>Çek</i>	0	0	0	0	1	212

**Çizelge 4.10.** Aktivite tanımada DVM yönteminin karmaşıklık matrisi

<i>RO</i>	<i>Tes</i>	<i>Mus</i>	<i>Vid</i>	<i>Boy</i>	<i>Mat</i>	<i>Çek</i>
<i>Tes</i>	221	0	0	0	0	1
<i>Mus</i>	0	85	4	1	1	0
<i>Vid</i>	0	15	73	0	1	1
<i>Boy</i>	0	0	0	198	0	0
<i>Mat</i>	0	0	0	2	160	0
<i>Çek</i>	0	0	0	0	8	118



## 5. SONUÇ ve ÖNERİLER

Bu çalışmada yürüme, koşma, snowboard, araç kullanma ve kayak yapma olmak üzere beş spor aktivitesinin yanı sıra musluk sıkma, vidalama, çekiçle delme, matkapla delme, testere ve boyama olmak üzere altı inşaat aktivitesinin bir bilekikte bulunan algılayıcılar ile sınıflandırılması problemi ele alınmıştır.

Spor aktiviteleri için on bin veri, inşaat aktiviteleri için ise altmış bin veri toplanılmıştır. Aktivitelere ait verileri toplamak için günlük hayatta kullanıma daha uygun olduğu düşünülen bileklik tercih edilmiştir. Aktivitelerden elde ettiğimiz ham veriler özniteliklere dönüştürülmüştür. Spor aktiviteleri için ivmeölçer kullanılarak yirmi iki öznitelik çıkarılmıştır. İnşaat aktiviteleri için ise ivmeölçer ve pusula kullanılarak kırk dört öznitelik çıkarılmıştır.

Literatür incelendiğinde, kayak aktivitesi tespitine yönelik tek bir çalışma bulunduğu, snowboard aktivitesi tespitine yönelik çalışma bulunmadığı belirlenmiştir. Bu çalışmada çok fazla çalışma olmayan kayak ve snowboard aktiviteler incelenmiştir. Kayak ve snowboard verilerinin öznitelik değerlerinin birbirinden belirgin oranda farklı olduğu ve snowboard aktivitesine ait değerlerin kayak aktivitesine göre daha yüksek olduğu gözlemlenmiştir. Bu durum snowboard aktivitesinin kayma sırasında kontrolü sağlamak için daha çok vücut hareketi gerektirmesine bağlanabilir. Genel performans olarak beş spor aktivitesine ait öznitelik değerlerinden oluşan veri kümesi ile yapılan aktivite tanıma çalışmasında RO, kNN, DVM ve NB sınıflandırma yöntemleri kullanılmıştır. Her yöntem için %90 üzerinde doğruluk elde edilmiştir. Belirlenen sınıflandırma yöntemleri arasında en yüksek doğruluk %98,7 ile RO yöntemi ve araç kullanma aktivitesi için elde edilmiştir.

Literatürde inşaat aktivitelerini tespitine yönelik yapılan sınırlı sayıda çalışmada veri toplama cihazının konumu aktiviteye göre değişmektedir. Gerçek hayatta inşaat işçilerinden böyle bir davranışın beklenmesi ya da işçilerin bu davranışa zorlanmaları

gerçekçi olmayacaktır. Mevcut çalışmalardaki bu eksiklik gözlemlenerek, bu çalışmada bileğe takılan bileklik kullanılmış ve veri toplama cihazının konumu tüm aktiviteler için aynı tutulmuştur. Seçilen aktiviteler için RO, NB, DVM ve kNN sınıflandırma yöntemlerine ait doğruluk yüzdeleri verilmiştir. Bu problem için en yüksek başarı, %99,7 doğruluk ile RO yöntemi ile vidalama aktivitesinin tespitinde elde edilmiştir.

Gelecek çalışmalarımızda daha farklı yöntemler ve algılayıcılar kullanarak daha karmaşık aktiviteler (inşaat alanında veya diğer alanlarda) için aktivite tanıma çalışmaları yapılması planlanmaktadır. Ayrıca kendi tasarladığımız bilekliği üreterek, veri toplamanın daha esnek ve ergonomik hale getirilmesi amaçlanmaktadır.

**KAYNAKLAR**

- Akhavian, R., & Behzadan, A. H. (2015). Construction equipment activity recognition for simulation input modeling using mobile sensors and machine learning classifiers. *Advanced Engineering Informatics*, 29(4), 867-877.
- Akhavian, R., & Behzadan, A. H. (2016). Smartphone-based construction workers' activity recognition and classification. *Automation in Construction*, 71, 198-209.
- Ashton, K. (2009). That 'internet of things' thing. *RFID journal*, 22(7), 97-114.
- Avci, A., Bosch, S., Marin-Perianu, M., Marin-Perianu, R., & Havinga, P. (2010, February). Activity recognition using inertial sensing for healthcare, wellbeing and sports applications: A survey. In 23th International conference on architecture of computing systems 2010 (pp. 1-10). VDE.
- Balli, S., Sağbas, E. A., & Hokimoto, T. (2017). The usage of statistical learning methods on wearable devices and a case study: activity recognition on smartwatches. *Advances in statistical methodologies and their application to real problems*, 259-277.
- Bıçakçı, S. N. Nesnelerin İnterneti. *Takvim-i Vekayi*, 7(1), 24-36.
- bin Abdullah, M. F. A., Negara, A. F. P., Sayeed, M. S., Choi, D. J., & Muthu, K. S. (2012). Classification algorithms in human activity recognition using smartphones. *International Journal of Computer and Information Engineering*, 6(77-84), 106.
- Bonomi, A. G., Goris, A. H., Yin, B., & Westerterp, K. R. (2009). Detection of type, duration, and intensity of physical activity using an accelerometer. *Medicine & Science in Sports & Exercise*, 41(9), 1770-1777.
- Bussmann, J. B. J., Martens, W. L. J., Tulen, J. H. M., Schasfoort, F. C., Van Den Berg-Emons, H. J. G., & Stam, H. J. (2001). Measuring daily behavior using ambulatory accelerometry: the Activity Monitor. *Behavior Research Methods, Instruments, & Computers*, 33(3), 349-356.
- Caruso, M. J. (1997). Applications of magnetoresistive sensors in navigation systems (No. 970602). SAE Technical Paper.
- Casale, P., Pujol, O., & Radeva, P. (2011, June). Human activity recognition from accelerometer data using a wearable device. In *Iberian Conference on Pattern Recognition and Image Analysis*(pp. 289-296). Springer, Berlin, Heidelberg.
- Chen, K. Y., & DAVID R BASSETT, J. R. (2005). The technology of accelerometry-based activity monitors: current and future. *Medicine & Science in Sports & Exercise*, 37(11), S490-S500.
- Clarkson, P. M., & Thompson, H. S. (2000). Antioxidants: what role do they play in physical activity and health?. *The American journal of clinical nutrition*, 72(2), 637S-646S.
- Cleland, I., Kikhia, B., Nugent, C., Boytsov, A., Hallberg, J., Synnes, K., ... & Finlay, D. (2013). Optimal placement of accelerometers for the detection of everyday activities. *Sensors*, 13(7), 9183-9200.
- Coşkun, C., & Baykal, A. (2011). Veri madenciliğinde sınıflandırma algoritmalarının bir örnek üzerinde karşılaştırılması. *Akademik Bilişim*, 2011, 1-8.

- Cover, T. M., & Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- Du, M., Kawashima, S., Yonemura, S., Zhang, X., & Chen, S. (2004). Mutual influence between human activities and climate change in the Tibetan Plateau during recent years. *Global and Planetary Change*, 41(3-4), 241-249.
- Ermes, M., Pärkkä, J., Mäntyjärvi, J., & Korhonen, I. (2008). Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions. *IEEE transactions on information technology in biomedicine*, 12(1), 20-26.
- Gjoreski, M., Gjoreski, H., Luštrek, M., & Gams, M. (2016). How accurately can your wrist device recognize daily activities and detect falls?. *Sensors*, 16(6), 800.
- Helmrich, S. P., Ragland, D. R., Leung, R. W., & Paffenbarger Jr, R. S. (1991). Physical activity and reduced occurrence of non-insulin-dependent diabetes mellitus. *New England journal of medicine*, 325(3), 147-152.
- Ichikawa, F., Chipchase, J., & Grignani, R. (2005). Where's the phone? A study of mobile phone location in public spaces.
- Kaytaran, T., & Bayindir, L. (2018, May). Activity recognition with wrist found in photon development board and accelerometer. In *2018 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Lara, O. D., & Labrador, M. A. (2012). A survey on human activity recognition using wearable sensors. *IEEE communications surveys & tutorials*, 15(3), 1192-1209.
- 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.
- Lee, I., & Lee, K. (2015). The Internet of Things (IoT): Applications, investments, and challenges for enterprises. *Business Horizons*, 58(4), 431-440.
- Lee, Y. S., & Cho, S. B. (2011, May). Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer. In *International Conference on Hybrid Artificial Intelligence Systems* (pp. 460-467). Springer, Berlin, Heidelberg.
- Mathie, M. J., Basilakis, J., & Celler, B. G. (2001). A system for monitoring posture and physical activity using accelerometers. In *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (Vol. 4, pp. 3654-3657). IEEE.
- Mitchell, E., Monaghan, D., & O'Connor, N. (2013). Classification of sporting activities using smartphone accelerometers. *Sensors*, 13(4), 5317-5337.
- Nath, N. D., Shrestha, P., & Behzadan, A. H. (2017, December). Human activity recognition and mobile sensing for construction simulation. In *Proceedings of the 2017 Winter Simulation Conference* (p. 197). IEEE Press.
- Ott, A. E., Pate, R. R., Trost, S. G., Ward, D. S., & Saunders, R. (2000). The use of uniaxial and triaxial accelerometers to measure children's "free-play" physical activity. *Pediatric Exercise Science*, 12(4), 360-370.
- Özger, Z. B., & Amasyalı, M. F. (2013, April). KNN parameter selection via meta learning. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

- Parkka, J., Ermes, M., Korpipaa, P., Mantyjarvi, J., Peltola, J., & Korhonen, I. (2006). Activity classification using realistic data from wearable sensors. *IEEE Transactions on information technology in biomedicine*, 10(1), 119-128.
- Ravi, N., Dandekar, N., Mysore, P., & Littman, M. L. (2005, July). Activity recognition from accelerometer data. In *Aaai* (Vol. 5, No. 2005, pp. 1541-1546).
- Rebolj, D., Babič, N. Č., Magdič, A., Podbreznik, P., & Pšunder, M. (2008). Automated construction activity monitoring system. *Advanced engineering informatics*, 22(4), 493-503.
- Ryder, J., Longstaff, B., Reddy, S., & Estrin, D. (2009, August). Ambulation: A tool for monitoring mobility patterns over time using mobile phones. In *2009 International Conference on Computational Science and Engineering* (Vol. 4, pp. 927-931). IEEE.
- Siirtola, P., & Rönig, J. (2012). Recognizing human activities user-independently on smartphones based on accelerometer data. *IJIMAI*, 1(5), 38-45.
- Su, X., Tong, H., & Ji, P. (2014). Activity recognition with smartphone sensors. *Tsinghua science and technology*, 19(3), 235-249.
- Suto, J., Oniga, S., & Sitar, P. P. (2017). Feature analysis to human activity recognition. *International Journal of Computers Communications & Control*, 12(1), 116-130.
- Wilde, A. G. (2010). An overview of human activity detection technologies for pervasive systems. *Department of Informatics University of Fribourg, Switzerland*, 212, 72-112.
- Yan, Z., Subbaraju, V., Chakraborty, D., Misra, A., & Aberer, K. (2012, June). Energy-efficient continuous activity recognition on mobile phones: An activity-adaptive approach. In *2012 16th international symposium on wearable computers* (pp. 17-24). Ieee.

## ÖZGEÇMİŞ

Tuba ŞAHİN 1991 yılında Erzurum’da doğdu. İlk, orta ve lise öğrenimini Erzurum’da tamamladı. 2010-2015 yılları arasında Karabük Üniversitesi Bilgisayar Mühendisliği bölümünde lisans derecesini aldı. Mezuniyetinin ardından 2016 yılında Atatürk Üniversitesi'nde yüksek lisans eğitimine başladı. Özel bir firmada yazılım ağırlıklı AR-GE faaliyetleri gerçekleştirmektedir.

