


İvmeölçer ve Nesnelerin İnterneti Tabanlı Gerçek Zamanlı İnsan Aktivite Tespiti

*¹ Kenan Erin, ² Cüneyt Bayılmış, ³ Barış Boru

¹Sakarya Uygulamalı Bilimler Üniversitesi, Mekatronik Mühendisliği, kenanerin@subu.edu.tr, 

²Sakarya Üniversitesi, Bilgisayar Mühendisliği, cbayilmis@sakarya.edu.tr, 

³Sakarya Uygulamalı Bilimler Üniversitesi, Mekatronik Mühendisliği, barisb@subu.edu.tr, 

Araştırma Makalesi

Geliş Tarihi: 13.10.2020

Kabul Tarihi: 10.12.2020

Öz

İnsan aktivite tespiti son zamanlarda popülerliği artan bir makine öğrenmesi problemi. Hareketi tespit etmek için ivmeölçer, jiroskop v.b sensörler veya kamera yardımıyla görüntü işleme yapılarak tahminler yapılabilmektedir. Bireylerden sensörler vasıtasıyla alınan veriler ön işlemde geçerek sınıflandırma algoritmaları ile sınıflandırılarak kişilerin hangi hareketi yaptıkları tespit edilmeye çalışılmaktadır. Bu çalışma kapsamında mobil cihaz için yapılan android yazılım ile cihazın ivmeölçer sensörü kullanılarak nesnelerin interneti tabanlı insan hareketlerinin tespiti gerçekleştirilmiştir. İlk önce tespiti yapılacak hareketler için veri toplanmıştır ve ön işlemde geçirilmiştir. Daha sonra oluşan veri setinden özellik çıkarımı yapılmıştır. Elde edilen veri üzerine Destek Vektör Makinaları, Rastgele Orman ve K En Yakın Komşuluk algoritmaları uygulanarak yapılan hareketler sınıflandırılmıştır. Sınıflandırma başarıları tespit edilmiş olup en başarılı sınıflandırma algoritması nesnelerin interneti tabanlı uygulama ile gerçek zamanlı sınıflandırma işlemi için kullanılmıştır.

Anahtar Kelimeler: İvmeölçer, İnsan Hareketi Tespiti, Nesneleri İnterneti, Destek Vektör Makinaları, Rastgele Orman, K En Yakın Komşuluk

Real-Time Human Activity Detection Based on Accelerometers and Internet of Things

*¹ Kenan Erin, ² Cüneyt Bayılmış, ³ Barış Boru

¹Sakarya University of Applied Science, kenanerin@subu.edu.tr

²Sakarya University, cbayilmis@subu.edu.tr

³Sakarya University of Applied Science, barisb@subu.edu.tr

Abstract

Human activity detection is a machine learning problem that has recently become more popular. Estimations can be done using image processing by means of accelerometer, gyroscope, sensor or camera to detect movement. The data obtained from the individuals through sensors is pre-processed and classified with classification algorithms to determine which movement they make. Within the scope of this study, the internet based human movements were determined by using the accelerometer sensor of a device with an android software made for the mobile device. First, data was collected and pre-processed for the movements to be determined. Then feature extraction was performed from the data set. The movements were classified by using Support Vector Machines, Random Forest and K Nearest Neighbour algorithms on the resulting data. Classification successes have been determined and the most successful classification algorithm has been used for real time classification of objects with internet based application.

Keywords: Accelerometer, Human Movement Detection, Internet of Things, Support Vector Machines, Random Forest, K Nearest Neighbour

1. GİRİŞ

Günümüzde akıllı telefon, akıllı saat ve akıllı gözlükler giyilebilir cihazların yaygınlaşması ile ivmeölçer, jiroskop gibi sensörlerden fazla miktarda veri toplanabilmektedir. Bu verileri kullanarak geliştirilen uygulamalarla kişilerin anlık olarak hareket tespiti yapılabilmektedir. Sensörlerden

alınan bilgiler makine öğreniminin temel konuları arasında yer almaktadır. Veriler ilk önce bir ön işlemde geçirilerek probleme uygun hale getirilip daha sonra makine öğrenimi algoritmaları ile anlamlandırılmaya çalışılmaktadır. Anlamlandırılan verilerden elde edilen sonuçlar ile insan makine etkileşim sistemleri geliştirilmektedir. Haberleşme yöntemlerinin geliştirilmesiyle uzak mesafelerden bilgi alış

*Sorumlu yazar: Sakarya Uygulamalı Bilimler Üniversitesi, Mekatronik Mühendisliği, kenanerin@subu.edu.tr

verişi hızlı bir şekilde yapılabilmektedir[1,2]. Nesnelerin interneti tabanlı geliştirilen uygulamalar ile akıllı telefonlardan veya çeşitli sensörler ile makine kontrolleri rahat bir şekilde yapılmaktadır. Sensörlerden alınan büyük datalar ilk önce internet üzerinde bulut platformuna daha sonra bir akıllı cihaz sayesinde bulut platformunda depolanan veriler alınıp işlenebilmektedir. Yapılan çalışmalarda insan hareketlerinin tespiti için genellikle kamera ile görüntü işleme , ivmeölçer benzeri sensörler veya bunların birleşimiyle hibrit yapılar oluşturulmaya çalışılmıştır. Son zamanlarda sensörlerin günlük hayatta kullandığımız akıllı telefon , akıllı saat gibi sistemlere entegre edilmesiyle dışarıdan başka bir sensöre ihtiyaç duyulmadan da hareket tespiti yapılabilmektedir.

Literatürde yapılan çalışmalar incelendiğinde daha çok büyük verilerden hareket tespiti yapılmaktadır. Mohamed ve ark.[3] telefondan aldıkları verilerle ivmeölçer tabanlı hareket tespiti sistemi geliştirmişlerdir. Yazarlar ilk önce verilerden özellik çıkarımı yapmışlardır. Daha sonra Principle Component Analysis (PCA) ve Linear Discriminant Analysis(LDA) algoritmaları ile verilerden boyut azaltma işlemi gerçekleştirmişlerdir. Veriler üzerinde derin öğrenme, destek vektör makinaları ve yapay sinir ağları uygulayarak hareketlerin tespit edilme başarı oranlarını elde etmişlerdir. Seung ve ark. [4] yaptıkları çalışmada ofiste çalışan insanların hareketlerini kola yerleştirdikleri ivmeölçer sensörü ile tespit etmeye çalışmışlardır. Yazarlar el yazısı yazma, okuma, klavye ile yazma, fareye tıklama, ayakta durma, yürüme ve merdiven çıkma olarak 7 farklı hareket tanımlamışlardır. Aldıkları sensör verisinden Desicion Trees (DT), Support Vector Machine(SVM), K-Nearest Neighbour(KNN) ve Ensemble Learning(EL) algoritmaları ile hareketleri sınıflandırıp hangi algoritmanın daha iyi sonuç verdiğini tespit etmişlerdir. Cagatay ve ark. [5] ivmeölçer tabanlı insan hareket tespit sistemi gerçekleştirmişlerdir. Yazarlar hazır aldıkları veri setini kullanarak hareket tespiti yapmışlardır. Sınıflandırma algoritmaları olarak J48 DT, Multi Layer Perceptron(MLP), Logistic Regression(LR) ve kendilerinin önerdiği bir sınıflandırma tekniği kullanmışlar ve sınıflandırma performanslarını belirlemişlerdir. Mohanad ve ark. [6] görüntü işleme tabanlı hareket tespiti uygulaması gerçekleştirmişlerdir. Yazarlar aldıkları videodan 5 farklı hareket belirlemiş daha sonra bu hareketler için özellik çıkarımı yapmışlardır. Belirledikleri hareketleri sınıflandırma için yapay sinir ağları kullanıp sınıflandırma başarılarını tespit etmişlerdir. Chen ve ark. [7] akıllı telefon kullanarak ivmeölçer tabanlı hareket tespiti uygulaması gerçekleştirmişlerdir. Yazarlar bu çalışmada 10 farklı kişiden aldıkları ivmeölçer verilerini SVM, Random Forest(RF) ve KNN algoritmaları ile sınıflandırmış ve sınıflandırma başarılarını belirtmişlerdir. Media ve ark. [8] yaptıkları çalışmada telefondan aldıkları ivmeölçer tabanlı hareket tanıma uygulaması gerçekleştirmişlerdir. Yazarlar 5 farklı hareket tespit edip bunlarla ilgili verileri telefon kullanarak toplamışlardır. Daha sonra Weka veri madenciliği programıyla farklı sınıflandırma algoritmalarını kullanarak hareketlerin sınıflandırma performanslarını

belirtmişlerdir. Mikka ve ark.[9] kalçaya ve bileğe yerleştirilen ivmeölçer sensörü ile 12 kişiden belirledikleri hareketler için veri toplamışlardır. Yazarlar aldıkları verilerden özellik çıkarımı yapıp daha sonra denetimli ve denetimsiz yapay sinir ağları ile hareketleri sınıflandırmışlardır. Yapılan sınıflandırma sonucu başarı performanslarını belirtmişlerdir. Erhan ve ark.[10] yaptıkları çalışmada telefonun ivmeölçer ve jiroskopunu kullanarak hareket tespiti uygulaması gerçekleştirmişlerdir. Çalışmada topladıkları data set üzerindeki gürültüleri gidermek için Butterworth ve median filtre kullanmışlardır. Daha sonra 6 farklı hareketi tespiti için Desicion Trees, Support Vector Machine, K –nearest neighbors ve Ensemble classification yöntemlerini kullanmış ve sonuçlarını karşılaştırmalı olarak sunmuşlardır. Çalışma sonunda Support Vector Machine algoritmasının daha başarılı sonuç verdiğini tespit etmişlerdir. Akhavian ve ark.[11] yaptıkları çalışmada inşaat işçilerinin hareketlerini tespit etmek için akıllı telefon kullanarak hareket tespiti uygulaması gerçekleştirmişlerdir. Yazarlar kola bağladıkları telefon üzerinden işçilerden örnekler toplamışlardır. Daha sonra aldıkları örnekler üzerinden Neural Netwok, Decision Tree, K- nearest neighbor, Logistic Regression ve Support Vector Machine algoritmalarıyla hareketleri sınıflandırmışlardır. Sınıflandırma sonucunda K- nearest neighbor algoritmasının daha iyi sonuç verdiğini tespit etmişlerdir. Akram ve ark.[12] yaptıkları çalışmada akıllı telefon kullanarak hareket tespiti uygulaması gerçekleştirmişlerdir. Yazarlar 6 farklı hareket için telefonun elde tutma durumu ve telefonun cepte tutma durumlarından 2 farklı data set oluşturmuşlardır. Daha sonra oluşturulan data setlerden farklı algoritmalar kullanarak sınıflandırma yapmışlardır. Çalışma sonunda kullandıkları algoritmalarından Multilayer Perceptron algoritmasının 2 farklı data set üzerinde daha iyi sonuç verdiğini tespit etmişlerdir. Esfahani ve Malazi[13] yaptıkları çalışmada akıllı telefon kullanarak hareket tespiti uygulaması gerçekleştirmişlerdir. Yazarlar ivmeölçer ve jiroskop kullanarak Position-Aware Muti Sensor(PAMS) adını verdikleri yeni bir data set oluşturmuşlardır. Oluşturdukları data seti 6 farklı algoritma ile sınıflandırmışlardır. Sınıflandırma sonucunda kullandıkları algoritmaların başarı performanslarını belirlemişlerdir.

Literatürde yapılan çalışmalara bakıldığında yazarlar genelde yapay zeka teknikleri ile hareket tespiti uygulaması gerçekleştirmişlerdir. İvmeölçer ve jiroskop cihazlarından aldıkları verilerle çevrimdışı çalışmalar yapılmış olup bunların başarı performanslarını belirlemişlerdir. Bu çalışmada ivmeölçer tabanlı insan hareket tespiti için gerçek zamanlı bir uygulama geliştirilmiştir. Çalışmada tasarlanan mobil android uygulama ile yürüme, oturma, merdiven çıkma, merdiven inme olmak üzere 4 farklı hareket belirlenmiş ve veri toplanmıştır. Toplanan verilere ilk önce ön işlem uygulanmış olup daha sonra oluşan veriler üzerinde farklı özellik çıkarımları yapılmıştır. Sınıflandırma algoritması için SVM, RF ve KNN algoritmaları kullanılmıştır. Sınıflandırma sonucunda elde edilen karışıklık matrisleri tespit edilip en başarılı algoritma ile

nesnelerin interneti tabanlı uygulama geliştirilip uzak mesafelerden gerçek zamanlı olarak kişilerin hangi hareketi yaptığı tespit edilmeye çalışılmıştır.

2. SİSTEM MİMARİSİ

Çalışmada akıllı telefonun ivmeölçer sensörü kullanılarak android tabanlı bir uygulama geliştirilmiştir. Çalışma 2 kısımdan oluşmaktadır. Birinci kısımda belirlenen 4 farklı hareket için 20'şer saniyelik veri toplanıp bu veri setinden ilk önce ön işlem daha sonra özellik çıkarımı yapılmıştır. Özellik çıkarımı yapıldıktan sonra verilerin sınıflandırılması için 3 farklı sınıflandırma algoritması kullanılmış olup bu algoritmaların sınıflandırma başarıları belirlenmiştir. İkinci kısımda ise gerçek zamanlı hareket tespiti için nesnelerin interneti tabanlı uygulama geliştirilmiştir. Bu uygulamada hareket halindeki kişilerin telefonlarındaki ivmeölçer verileri anlık olarak bulut platformuna aktarılmıştır. Birinci kısımda sınıflandırma başarıları en iyi olan algoritma gerçek zamanlı sınıflandırma için kullanılarak kişilerin yaptıkları hareketler anlık olarak tespit edilmiştir. Bulut platformu olarak Google Firebase, sınıflandırma işlemi için Python'da sklearn kütüphanesi kullanılıp yazılım geliştirilmiştir

2.1. Veri Toplanması

İvmeölçer 3 boyutlu uzayda açısal değişimi ölçmeye yarayan cihazdır. Teknolojinin gelişmesiyle birlikte ivmeölçerler akıllı telefonlara, akıllı saatlerde kullanılmaya başlanmıştır. Veri toplanması için akıllı telefon üzerinden android yazılım geliştirilmiştir. Cebe yerleştirilen telefon ile oturma, yürüme, merdiven çıkma ve merdiven inme hareketleri için istenilen sürede 3 boyutlu ivmeölçer verisini kayıt edilmiştir. Çalışmada her bir hareket türü için 20'şer saniye boyunca ivmeölçer verisi kayıt edilmiştir. Gerçek zamanlı uygulamada ise 1'er saniyelik ivmeölçer verisi anlık olarak bulut platformu ile uzaktaki bir bilgisayarda Python ortamına gönderilmiştir. Veri toplamak için geliştirilen android uygulama Şekil 1'de gösterilmiştir.



Şekil 1. Sınıflandırma İçin Veri Toplama Uygulaması

2.2. Özellik Çıkarımı

Çalışma kapsamında toplanan 3 boyutlu ivmeölçer verisiyle sınıflandırma yapmak çok doğru sonuçlar vermeyebilir. Elde edilen verinin dışında bu veriyi temsil edebilecek başka özelliklerin oluşturulup sınıflandırma algoritmasına

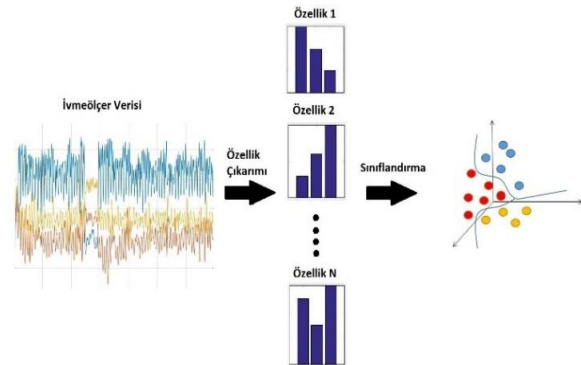
verilmesi gerekmektedir. Böylece sınıflandırma daha iyi bir başarıyla gerçekleşecektir. Yapılan çalışmada 3 boyutlu ivmeölçer verisinin dışında her ivmeölçer verisinin ortalaması (3 özellik), standart sapması (3 özellik) ve ivmelerin kareleri toplamı(1) özellik olmak üzere toplam 10 özellik belirlenip sınıflandırma algoritmasına gönderilmiştir.

2.3 Sınıflandırma

Sınıflandırma veri kümesinde bulunan bireylerin özelliklerine göre ayrılması işlemidir. Bu işlem 2 aşamadan oluşmaktadır. Birinci aşama toplanan verilerle kullanılan sınıflandırma algoritmalarının eğitim aşaması ikinci aşama ise bilinmeyen bir veri ile eğitilen sınıfların test edilme aşamasıdır. Çalışma kapsamında başarı oranlarını ölçmek için 3 farklı sınıflandırma algoritması kullanılmıştır.

- **Destek Vektör Makinaları (DVM):** Destek Vektör Makinaları Vapnik ve ark.[14] tarafından geliştirilen bir makine öğrenmesi algoritmasıdır. Destek Vektör Makinalarında amaç verileri birbirinden ayıracak bir hiperdüzlemi belirlemektir. Veriler birbirinden ayrılırken birden fazla düzlem ile ayrılabilirler. Sınıfları birbirine en uzak yapan hiperdüzlemi belirleyerek ayrıştırma yapan bir algoritmadır.
- **Rastgele Orman:** Rastgele Orman Leo Breiman [15] tarafından geliştirilen ve birden fazla karar ağacının birleştirilmesiyle sınıflandırma başarıları yükseltmeyi amaçlayan bir makine öğrenmesi algoritmasıdır. Rastgele orman sınıflandırılmasında veri seti tek bir sınıfa ayrılana kadar düğümlere bölünür ve sonucunda tüm verinin birbirinden ayrılmasıyla sonuçlanır.
- **K En Yakın Komşuluk :** K En Yakın Komşuluk algoritması basit ama güçlü sınıflandırma yapısı ile bilinen bir makine öğrenme tekniğidir. Bu algoritmada amaç seçilen bir k parametresine göre sınıflandırılmak istenen verinin kendisine en yakın k tane verinin sınıfına bakılması esasına dayanmaktadır. K tane elemandan hangisinin sınıfı daha fazla ise kendisini o sınıfa üye eden bir algoritmadır

Yapılan çalışmanın veri işleme aşamaları Şekil 2'de gösterilmiştir.



Şekil 2. Sınıflandırma İçin Veri İşleme Aşamaları

3. DENEYSSEL ÇALIŞMA

Yapılan çalışmada belirlenen 4 farklı hareket için 20'şer saniyelik eğitim verisi toplanmıştır. Saniyede 50 veri toplanmış olup 1000 adet veri toplanmıştır. Elde edilen veriler eğitim ve test aşamalarında kullanılmıştır. Kullanılan verilerden 900 tanesi eğitim aşaması 100 tanesi test aşaması için kullanılmıştır. 1000 tane veriden eğitim ve test verisini belirlemek için k-cross validation yöntemi kullanılmış olup k parametresi 5 olarak seçilmiştir. Daha sonra verileri destek vektör makinaları, rastgele orman ve k en yakın komşuluk sınıflandırma algoritmaları ile eğitilmiştir. Eğitim aşaması bittikten sonra karışıklık matrisleri ve en başarılı algoritmanın tespiti için test verisi ile kontrol gerçekleştirilmiştir. Destek vektör makinaları, rastgele orman ve k en yakın komşuluk algoritmaları ile sınıflandırmada elde edilen karışıklık matrisleri ve sınıflandırma başarıları Tablo 1,2 ve 3'de gösterilmiştir.

Tablo 1. Destek Vektör Makinaları Karışıklık Matrisi

	Oturma	Yürüme	Merdiven İne	Merdiven Çıkma	Ortalama
Oturma	100	0	0	0	100
Yürüme	0	98	2	0	98
Merdiven İne	0	2	95	3	95
Merdiven Çıkma	0	4	3	93	93

Tablo 2. Rastgele Orman Karışıklık Matrisi

	Oturma	Yürüme	Merdiven İne	Merdiven Çıkma	Ortalama
Oturma	100	0	0	0	100
Yürüme	0	100	0	0	100
Merdiven İne	0	0	95	5	95
Merdiven Çıkma	0	2	1	97	97

Tablo 3. K En Yakın Komşuluk Karışıklık Matrisi

	Oturma	Yürüme	Merdiven İne	Merdiven Çıkma	Ortalama
Oturma	100	0	0	0	100
Yürüme	0	85	10	5	85
Merdiven İne	0	4	65	31	65
Merdiven Çıkma	0	6	14	80	80

Tablo 1,2 ve 3 de verilen karışıklık matrislerine bakıldığında yapılan çevrimdışı sınıflandırmada kullanılan 3 farklı algoritmanın hangisinin daha başarılı olduğu görülmektedir. 4 farklı hareket tespiti için SVM algoritması ile yapılan sınıflandırmada başarıları %96.5 , rastgele orman algoritması ile yapılan sınıflandırma başarıları % 98 ve k en yakın komşuluk algoritması ile yapılan sınıflandırma başarıları %82.5 olarak belirlenmiştir. Sınıflandırma başarılarına bakıldığında en başarılı algoritmanın rastgele orman algoritması olduğu görülmektedir. Bu algoritma gerçek zamanlı sınıflandırma için kullanılmıştır.

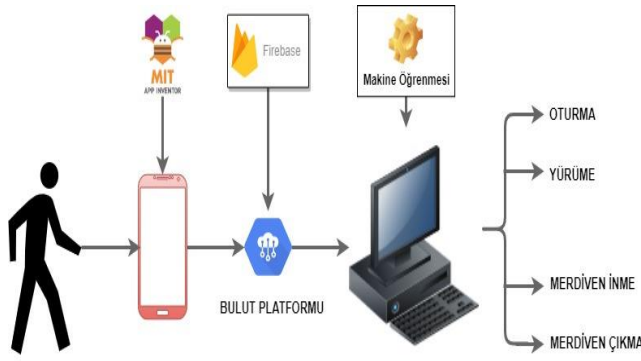
4. NESNELERİN İNTERNETİ TABANLI GERÇEK ZAMANLI UYGULAMA

İnternet, sanal düzeyde etkileşimlerden sosyal ilişkilere kadar yaşamımızdaki varlığını göstermektedir. Nesnelerin interneti nesnelere ve insan arasındaki iletişimi sağlayarak, cihazların daha akıllı hale geldiği, günlük iletişimin daha efektif olduğu platform olarak söylenebilir. Bu platform algılama, çalıştırma, kontrol ve izleme faaliyetlerini yürüten cihazlardan veri toplamaktadır. Nesnelerin interneti cihazları diğer bağlı cihazlarla veri alışverişi yapabilir ve diğer cihazlardan veri toplayıp işleyebilmektedir. Ericsson şirketi iletişim ağlarına bağlı cihazların sayısının 2016'da 16 milyara ulaştığı ve 2022'de 29 milyara ulaşacağı tahmin etmektedir[16]. Bu çalışmada nesnelerin interneti ile uzak mesafeden alınan ivmeölçer verileriyle kişilerin hareketinin gerçek zamanlı olarak tespiti yapılmıştır. Sağ ön cebe yerleştirilen telefonda gerçek zamanlı olarak veri toplanmıştır. Çalışma için android tabanlı bir uygulama geliştirilmiştir. Geliştirilen android uygulama Şekil 3 'de gösterilmiştir.



Şekil 3. Nesnelerin İnterneti Tabanlı Geliştirilen Uygulama

3 boyutlu ivmeölçer verisi internet üzerinde bulut ortamında depolanmıştır. Daha sonra uzaktan bir ana bilgisayarda depolanan veriler Python ortamına gerçek zamanlı olarak alınmış ve hareketin tespiti sağlanmıştır. Sınıflandırma algoritması olarak çevrimdışı sınıflandırmada en başarılı algoritma olarak belirlenen Rastgele Orman algoritması kullanılmıştır. Yapılan gerçek zamanlı uygulama modeli Şekil 4'de gösterilmiştir



Şekil 4. Gerçek Zamanlı Hareket Tespiti

5. SONUÇLAR

Bu çalışmada ivmeölçer ve nesnelerin interneti tabanlı gerçek zamanlı insan hareket tespiti uygulaması geliştirilmiştir. Çalışmada ilk önce belirlenen hareketler için belirli zaman aralığında veri toplanmıştır. Daha sonra toplanan bu veriler 3 farklı sınıflandırma algoritması ile çevrimdışı olarak sınıflandırılmıştır. Sınıflandırma sonucunda en iyi sınıflandırma algoritması rastgele orman olarak belirlenmiş olup gerçek zamanlı uygulama için bu algoritma kullanılmıştır. Sınıflandırma algoritmalarının yüksek başarı oranı vermesi akıllı telefonların hareket tespiti uygulamalarında rahatça kullanılabileceğini göstermiştir. Gerçek zamanlı çalışma için nesnelerin interneti tabanlı bir android uygulama geliştirilmiştir. Bu uygulama ivmeölçer verisini bulut ortamına göndermektedir. Python ortamında geliştirilen yazılım ile gerçek zamanlı veriler bulut ortamından alınarak sınıflandırma sonucu kişilerin hareketleri tespit edilmektedir. Çalışma süresince gecikmeler meydana geldiği tespit edilmiş olup sınıflandırma işleminin sorunsuz bir şekilde çalıştığı gözlemlenmiştir.

Yapılan çalışmalara bakıldığında yaptığımız çalışmanın literatürden farkları aşağıda verilmiştir:

- Android tabanlı uygulama geliştirilerek gerçek zamanlı hareket tespitini yapılması
- Nesnelerin interneti yönteminin yaptığımız çalışmaya ekleyerek kişilerin mekan farkı gözetmeksizin sürekli olarak hareketinin izlenebilmesi. Ayrıca geliştirilen android uygulamanın kişilere özel olarak kullanılabilmesinin sağlanması
- Kendi oluşturduğumuz data set üzerinde yapılan sınıflandırma çalışmasının yüksek başarıya ulaşması

KAYNAKÇA

[1]. Uddin, M. Z. "A wearable sensor-based activity prediction system to facilitate edge computing in smart

healthcare system". *Journal of Parallel and Distributed Computing*, 123, 46-53,2019.

[2]. Yamada, Y., Shinkuma, R., Iwai, T., Onishi, T., Nobukiyo, T., & Satoda, K. "Temporal traffic smoothing for IoT traffic in mobile networks". *Computer Networks*, 146, 115-124, 2018..

[3]. M. M. Hassan, M. Z. Uddin, A. Mohamed, and A. Almogren, "A robust human activity recognition system using smartphone sensors and deep learning," *Futur. Gener. Comput. Syst.*, vol. 81, pp. 307–313, 2018.

[4]. S. H. Cha, J. Seo, S. H. Baek, and C. Koo, "Towards a well-planned, activity-based work environment: Automated recognition of office activities using accelerometers," *Build. Environ.*, vol. 144, no. April, pp. 86–93, 2018.

[5]. C. Catal, S. Tufekci, E. Pirmitt, and G. Kocabag, "On the use of ensemble of classifiers for accelerometer-based activity recognition," *Appl. Soft Comput. J.*, vol. 37, pp. 1018–1022, 2015.

[6]. M. Babiker, O. O. Khalifa, K. Kyaw Htike, A. Hassan, and M. Zaharadeen, "Automated Daily Human Activity Recognition for Video Surveillance Using Neural Network," *Proc. 4th IEEE Int. Conf. Smart Instrumentation, Meas. Appl.*, no. November, pp. 28–30, 2017.

[7]. Y. Chen and C. Shen, "Performance Analysis of Smartphone-Sensor Behavior for Human Activity Recognition," *IEEE Access*, vol. 5, pp. 3095–3110, 2017.

[8]. M. A. Ayu, S. A. Ismail, A. F. Abdul Matin, and T. Mantoro, "A comparison study of classifier algorithms for mobile-phone's accelerometer based activity recognition," *Procedia Eng.*, vol. 41, no. Iris, pp. 224–229, 2012.

[9]. Ermes, M., Pärkkä, J., Mäntyjärvi, J., & Korhonen, I. "Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions". *IEEE transactions on information technology in biomedicine.*,vol. 12,pp. 20-26,2008.

[10]. Bulbul, E., Cetin, A., & Dogru, I. A. (2018, October). Human activity recognition using smartphones. In 2018 2nd international symposium on multidisciplinary studies and innovative technologies (ismsit) (pp. 1-6). IEEE.

[11]. Akhavian, R., & Behzadan, A. H. (2016). Smartphone-based construction workers' activity recognition and classification. *Automation in Construction*, 71, 198-209.

[12]. Bayat, A., Pomplun, M., & Tran, D. A. (2014). A study on human activity recognition using accelerometer data from smartphones. *Procedia Computer Science*, 34, 450-457.

[13]. Esfahani, P., & Malazi, H. T. (2017, December). PAMS: A new position-aware multi-sensor dataset for human activity recognition using smartphones. In 2017 19th International Symposium on Computer Architecture and Digital Systems (CADS) (pp. 1-7). IEEE.

[14]. C. Cortes, V. Vapnik, Support-vector networks, *Machine learning*, vol. 20(3), pp. 273-297,1995
Breiman, L.." Random forests". *Machine learning*,vol. 45,pp. 5-32, 2001.

[15]. Ericsson mobility report june 2017 (<https://www.ericsson.com/assets/local/mobilityreport/documents/2017/ericsson-mobility-report-june-2017.pdf>)