





A new dataset for human activity recognition and its classification with deep learning models

Yasin Vurgun^{1*} , Mustafa Servet Kiran² 

¹Department of Information Technologies, Adnan Akgul Special Education Vocational High School, Konya, Türkiye

²Department of Computer Engineering, Konya Technical University, Konya, Türkiye

Highlights:

- A new dataset was created containing 8 different activities, including the prayer (salat)
- It comprises multi-sensor data collected simultaneously through a smartwatch
- The success of 3 different LSTM models has been investigated by using StratifiedKfold

Keywords:

- Human Activity Recognition
- Smartwatch sensor data
- LSTM
- CNN-LSTM
- ConvLSTM

Article Info:

Research Article
Received: 11.07.2023
Accepted: 23.05.2024

DOI:

10.17341/gazimmfd.1325926

Correspondence:

Author: Yasin Vurgun
e-mail:
yasin_vurgun@hotmail.com
phone: +90 332 205 1542

Graphical/Tabular Abstract

Human activity recognition, briefly HAR, with mobile sensors has become an interesting research area in recent years due to increasing the wearable and mobile sensors. In Muslim life, the prayer (salat) is an activity that believers must perform five times a day. In this study, a novel dataset which also includes praying (salat) is presented to be used in human activity recognition. The dataset we call HAR-P (Human Activity Recognition for Praying) includes linear acceleration, acceleration, magnetic field and gyroscope sensors data for 8 activities such as walking, running, typing, walking, downstairs, walking upstairs, sitting, standing and praying. For the HAR-P dataset, the data were collected from 50 male volunteers between the ages of 15-60 with a smartwatch. General view of the study is shown in Figure A.

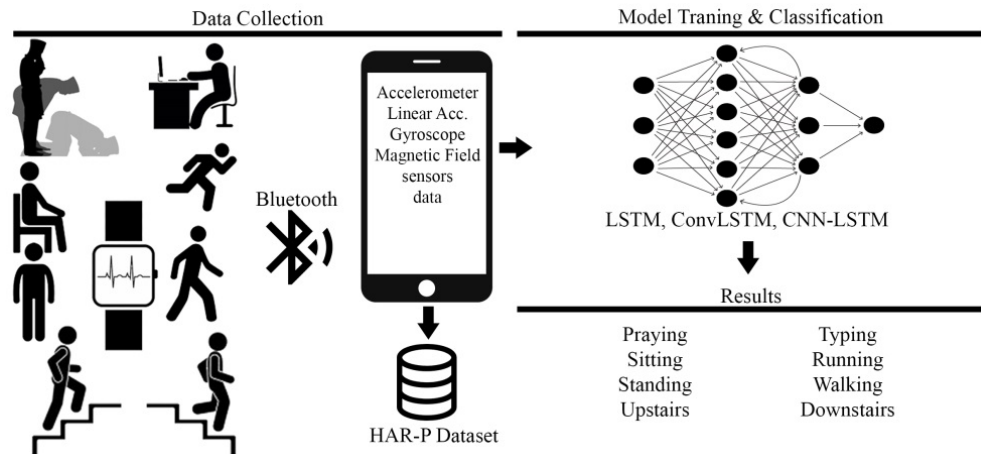


Figure A. General view of the study

Purpose:

The main purpose of this study is to create a new dataset which includes sensors data come from a smartwatch to detect whether a Muslim prays or not by using deep learning models.

Theory and Methods:

The dataset has been created data come from the acceleration sensor, linear acceleration sensor, magnetic field sensor and gyroscope sensor. The collected dataset, named HAR-P, has been used for training and testing the deep learning models such as LSTM, Conv-LSTM and CNN-LSTM methods.

Results:

The human activity has been detected with the sensor data obtained from the smartwatch attached to the wrist. In the classification of human activity, all 3 models gave similar results for datasets. While the highest average success rate of 91% was achieved by using LSTM model with the linear acceleration sensor, and the ConvLSTM model with the acceleration sensor, the lowest average success rate of 83.6% was achieved with the gyroscope sensor and ConvLSTM model.

Conclusion:

The human recognition dataset with praying has been created, and three deep learning models have been applied to this dataset. The sensors embedded in a smartwatch have been used for detecting whether a Muslim prayed or not with a 91% success rate.



İnsan aktivite tanınması için yeni bir veri kümesi ve derin öğrenme modelleri ile sınıflandırılması

Yasin Vurgun^{1*}, Mustafa Servet Kıran²

¹Bilişim Teknolojileri Bölümü, Adnan Akgül Özel Eğitim Meslek Lisesi, Konya, Türkiye

²Bilgisayar Mühendisliği Bölümü, Konya Teknik Üniversitesi, Konya, Türkiye

ÖNEÇİKANLAR

- Namaz kılma dâhil olmak üzere 8 farklı aktiviteyi içeren yeni bir veri kümesi oluşturulmuştur
- Akıllı saat üzerinden aynı anda toplanan çoklu sensör verisi içermektedir
- 3 farklı LSTM modelinin başarısı, tabakalı k-katlı çapraz doğrulama (StratifiedKfold) ile araştırılmıştır

Makale Bilgileri

Araştırma Makalesi

Geliş: 11.07.2023

Kabul: 23.05.2024

DOI:

10.17341/gazimmfd.1325926

Anahtar Kelimeler:

İnsan aktivite tanınma,
akıllı saat sensör verisi,
lstm,
cnn-lstm,
convlstm

ÖZ

Mobil sensörler ile insan aktivite tanıma, giyilebilir ve mobil sensörlerin artması nedeniyle son yıllarda ilgi çekici bir araştırma alanı haline gelmiştir. Müslüman hayatında Namaz, müminlerin günde beş vakit kılmak zorunda oldukları bir aktivitedir. Bu çalışmada, insan aktivitesi tanımadaki kullanılmak üzere namaz kılmayı da içeren yeni bir veri kümesi sunulmaktadır. HAR-P adını verdiğimiz veri setinde yürüme, koşma, yazı yazma, merdiven inme, merdiven çıkma, oturma, ayakta durma ve namaz kılma gibi 8 aktivite için doğrusal hızlanma, ivme, manyetik alan ve jiroskop sensör verileri yer almaktadır. HAR-P veri seti için akıllı saat ile 15-60 yaş arası 50 erkek gönüllüden veri toplanmıştır. HAR-P veri kümesinde LSTM, ConvLSTM ve CNN-LSTM modellerinin sınıflandırma başarısı karşılaştırılmıştır. Ortalama en yüksek başarı oranı olan %91'e doğrusal hızlanma sensörü ile LSTM yöntemi ve ivme sensörü ile ConvLSTM modelinde ulaşıırken, en düşük ortalama başarı oranı olan %83,6'a jiroskop sensörü ve ConvLSTM yöntemi ile ulaşılmıştır.

A new dataset for human activity recognition and its classification with deep learning models

HIGHLIGHTS

- A new dataset was created containing 8 different activities, including the prayer (i.e., salat)
- It comprises multi-sensor data collected simultaneously through a smartwatch
- The success of 3 different LSTM models has been investigated by using StratifiedKfold

Article Info

Research Article

Received: 11.07.2023

Accepted: 23.05.2024

DOI:

10.17341/gazimmfd.1325926

Keywords:

Human activity recognition,
smartwatch sensor data,
lstm, cnn-lstm,
convlstm

ABSTRACT

In recent years, the use of mobile sensors for human activity recognition has become an intriguing research area due to the proliferation of wearable and mobile sensors. In Muslim life, the prayer (Salah) is an activity that believers are obligated to perform five times a day. In this study, a new dataset, including Salah, is presented for use in human activity recognition. Named HAR-P (Human Activity Recognition for Praying), the dataset comprises linear acceleration, acceleration, magnetic field, and gyroscope sensor data for eight activities: walking, running, typing, downstairs, upstairs, sitting, standing, and praying. Data were collected from 50 male volunteers aged 15-60 using a smartwatch for the HAR-P dataset. The classification performance of LSTM, ConvLSTM, and CNN-LSTM models was compared for the HAR-P dataset. The highest average classification accuracy of 91% was achieved with the LSTM method using linear acceleration sensor data and the ConvLSTM model using acceleration sensor data, while the lowest average accuracy of 83.6% was attained with the gyroscope sensor data and the ConvLSTM method.

1. Giriş (Introduction)

İnsan aktivite tanıma (Human Activity Recognition - HAR), çeşitli algılama cihazlarından elde edilen verilere dayalı olarak, bir kişinin belirli hareketini veya eylemini tanımlamaya ilgili çalışma alanıdır. Aktivite tanıma problemleri, kameradan alınan görüntülerin işlenmesi veya sensörlerden alınan sayısal değerlerin işlenmesi şeklinde iki yaklaşımla çözülebilmektedir [1, 2]. Bu makalede sensör tabanlı çalışmalar referans alınmıştır. Sensör odaklı çalışmalarda veriler, sensör barındıran cihazların kişinin üzerine yerleştirilmesi ile ya da kullanıcının bulunduğu ortama yerleştirilen radar tarzı cihazlardan toplanmasıyla elde edilmektedir. Sensör tabanlı aktivite tanıma problemlerindeki aktiviteler, basit ve karmaşık olarak ikiye ayrılmaktadır [3]. Basit aktiviteler yürüme, merdiven inme gibi tek bir aktiviteden oluşurken; karmaşık aktiviteler yemek pişirme, dış fırçalamaya gibi birçok aktiviteyi bünyesinde barındırabilmektedir. Literatürde basit aktiviteler olan oturma, ayakta durma, yürüme, koşma, merdiven inme ve merdiven çıkma aktiviteleri üzerinde yoğunlukla çalışılmıştır [4-7]. Basit aktivitelerin yanı sıra günlük yaşamda karmaşık aktiviteler de bulunmakta olup bu aktiviteler temelde birkaç set aktivitenin birleşiminden oluşmakta ve basit aktivitelere nazaran işlenmesi/sınıflandırılması görece daha zordur.

Sensör tabanlı aktivite tanıma yönelik çalışmalar için veri toplama aşamasında genelde akıllı telefonlar [8-10] ve giyilebilir cihazlar [11, 12] kullanılmaktadır. Veri toplama için kullanılan algılayıcılar, vücutta farklı konumlara yerleştirilebilmektedir: pantolon cebi [13-14], bel [15-17], el-kol [18-21], göğüs [16, 21], ayak-bacak [16, 22], çanta [23], baş [16]. Sensörlerden gelen veriler öncelikle sensör donanımının dâhili hafızasında toplanıp daha sonra bilgisayar ortamına aktarılmaktadır. Bundan dolayı veri toplamak için kullanılacak cihazlara özel uygulamalar geliştirilmektedir [4]. Bu uygulamalar ile veri toplamaya başlamadan örnekleme frekansı (sampling rate) ve kullanılacak sensörlerin önceden seçilmesi gerekmektedir [4, 24-26]. Örnekleme frekansı sensörden saniyede ne kadar veri alınacağını ifade etmekte olup literatürde 10 Hz/s [27], 12 Hz/s [19], 16 Hz/s [20], 20 Hz/s [4, 28], 25 Hz/s [29], 32 Hz/s [21, 28], 40 Hz/s [6], 50 Hz/s [14-16, 30, 31] ve 100 Hz/s [14, 22, 25, 32] şeklinde farklı parametre ayarlamaları bulunmaktadır. Sınıflandırılan aktiviteler insan hareketleri olduğundan dolayı düşük örnekleme frekanslarında başarılı sonuçlar elde edilebilmektedir.

Günlük yaşamımızda artık vazgeçilmez olan akıllı telefonlar ve akıllı saat gibi giyilebilir cihazlarda ivmeölçer, jiroskop, manyetik alan ölçer, GPS, kalp atış hızı ölçer, sıcaklık sensörü gibi sensörler bulunmaktadır. Bu sensörlerden ivmeölçer, jiroskop, manyetik alan ölçer, GPS ve mikrofon aktivite tanıma için tekli veya grup halde kullanılmaktadır. Sadece ivmeölçer sensörü ile yapılan aktivite tanıma oranları, jiroskop ve manyetik alan ölçer gibi ilave sensörlerin kullanılmasıyla arttırılabilmektedir [33]. Sensör tabanlı çalışmaların çok çeşitli alanlarda uygulamaları bulunmaktadır. Kuncan vd. [34] vücudun beş bölgesine yerleştirdikleri ivmeölçer, manyetometre ve jiroskop sensör verilerini kullanarak cinsiyet tanıma çalışması yapmışlardır. Yüksel vd. [35] giyilebilir cihazdaki ivmeölçer ve jiroskop sensör verisi kullanarak yazma davranışını sınıflandırmışlar ve biyometrik özellikler gösterdiğini belirtmişlerdir. Yaşlı insanların düşmesinin tespit edilmesine yönelik bir çalışma bulunmaktadır [36], başka bir çalışmada GPS, ivmeölçer ve jiroskop sensör verileri kullanılarak yürüme, koşma, bisiklet sürme, araba kullanma gibi farklı ulaşım türlerinin tespiti yapılmıştır [37]. Literatürde akıllı telefonlardaki sensörler, akıllı saatlerdeki sensörler ve diğer sensörlerle aktivite verilerini barındıran kullanıma açık hazır veri kümeleri bulunmaktadır. Wireless Sensör Data Mining (WISDM) Laboratuvar, "Actitracker" adında paylaştıkları veri seti doğal ortamda (real world) toplanmış altı basit aktivite içermektedir [38].

Yine WISDM Laboratuvar tarafından kontrollü laboratuvar ortamında toplanmış, altı basit aktivite içeren "Activity Prediction" başlıklı başka bir veri seti paylaşılmıştır [4]. "Skoda mini checkpoint" veri seti, araba tamir eden bir kişinin koluna yerleştirilmiş sensörler ile toplanan on el hareketinden oluşmaktadır [39]. "Opportunity" veri seti farklı türdeki cihazlardan toplanmış olup, dört kişinin toplam beş aktivite, onüç aksiyon ve onyedil el hareketinden oluşmaktadır [40]. Bu çalışma kapsamında literatürden farklı olarak; güncel akıllı saatlerde bulunan sensörlerden, namaz kılma gibi karmaşık bir aktiviteyi de içeren yeni bir veri seti oluşturulmuş ve literatürde kabul görmüş derin öğrenme modelleri kullanılarak insan hareket aktivite sınıflandırılması yapılmıştır.

1.1. Çalışmanın Ana Katkısı (Main Contribution of the Study)

Teknolojideki gelişmelerle birlikte elektronik ürünlerin boyutları küçülmüş ve yenilikçi yaklaşımlarla insan üzerine giyilebilir ürünlere dönüşmüştür. Giyilebilir teknolojiler denilen bu ürünler birçok algılayıcı barındırmaktadırlar. İçindeki algılayıcılar ile toplanan verilerle birçok alanda çalışmalar yapılabilmektedir. Giyilebilir ürünlerin başında akıllı saatler gelmektedir. Akıllı saatler, günümüzde çoğunlukla spor aktivite takibi, uyku düzeni takibi gibi amaçlarla kullanılmaktadır.

Namaz, İslam'ın beş şartından biri olarak büyük dini öneme sahiptir ve müminler, gün içinde beş kez belirli zamanlarda bu ibadeti yerine getirirler: sabah, öğle, ikindi, akşam ve yatsı namazları. Ancak, modern yaşamın getirdiği yoğunluk ve zaman kısıtlamaları bazen bu ibadetin zamanında gerçekleştirilmesini zorlaştırabilir. Bu sebeple, namaz ibadetinin tanınması ve takibi, teknolojinin sunduğu imkanlarla desteklenmelidir. Mevcut uygulamalar genellikle bulunan konuma göre namaz vakitlerini bildirmekte ve vaktin çıkmasından belirli bir süre önce namaz vaktini hatırlatmaktadır. Ancak hiçbir uygulama, kişinin namaz kılma durumunu takip etmemektedir. Bu çalışmada, bu ihtiyacı gidermek için günlük aktivitelerle birlikte namaz aktivitesini de içeren bir veri kümesi oluşturularak, sensör verilerinden oluşan zaman serilerini üç farklı derin öğrenme modeliyle sınıflandırma karşılaştırmasını gerçekleştirilmiştir. Oluşturulan yeni veri kümesi, paylaşılma açılacak olup, yeni çalışmalarda kullanılmak üzere alana katkı sağlayacağı düşünülmektedir. Bu bağlamda çalışmanın ana katkısı aşağıda kısaca özetlenmiştir.

- Literatüre namaz aktivitelerini de içeren yeni bir veri kümesi kazandırılmıştır.
- Namaz kılıpı kılınmadığını tespit etmek amacıyla üç farklı LSTM yöntemiyle performans analizi yapılmıştır.

2. Materyal ve Metot (Material and Method)

Bu bölümde insan aktivite sınıflandırması için yeni oluşturulan HAR-P veri kümesinin açıklaması, analizi yapılmış ve literatürdeki mevcut derin öğrenme modelleriyle sınıflandırılması gerçekleştirilmiştir. HAR-P veri kümesi oluşturulurken kullanılan sensörler, verinin toplanma şekli, kullanılan veri toplama yazılımı, verinin toplanma sıklığı, verinin etiketlenmesi, verini görselleştirilmesi konularında açıklamalar yapılmış olup HAR-P veri kümesinin ayrıntılı analizi gerçekleştirilmiştir.

Bu çalışmada kullanılan metot ve yöntemi ifade eden çalışmanın genel görünümü Şekil 1'deki gibidir. Öncelikle sekiz farklı aktivite için kullanıcılardan akıllı saat ile veri toplanmış, veriler belirli çerçeveye boyutunda segmentasyon edilerek eğitim ve test verisi olarak 5 katlı çapraz doğrulama yapmak için hazırlanmıştır. Ardından model eğitimi yapıp model başarıları değerlendirilmektedir.

2.1. Veri Kümesi Açıklaması (Dataset Description)

HAR-P veri kümesi, namaz kılma eyleminin tespit edilebilmesi amacıyla oluşturulmuş yeni bir insan aktivite sınıflandırması veri kümesidir. Veri kümesi 'Downstairs', 'Running', 'Sitting', 'Standing', 'Typing', 'Upstairs', 'Walking', 'Praying' aktivitelerini içermektedir. HAR-P veri kümesi dört farklı sensör için dört farklı ".csv" uzantılı dosyadan oluşmaktadır.

2.1.1. Kullanılan Sensörler (Sensors used)

HAR-P veri kümesi, sekiz farklı aktivite için akıllı saatten elde edilmiş; İvmeölçer (Accelerometer), Jiroskop (Gyroscope), Manyetik alan (Magnetic field) ve Doğrusal Hızlanma (Linear Acceleration) sensör verileri içermektedir.

2.1.1.1. İvmeölçer sensörü (Accelerometer sensor)

Cihaza x, y ve z eksenindeki uygulanan ivmeyi ölçer. İvmeyi üç eksen doğrultusunda m/s^2 olarak sayısal değer olarak döndürür. Bu sensör yardımıyla her üç eksendeki hızlanma değeri elde edilir. Elde edilen bu değerlerde yerçekimi kuvvetinin etkisi de bulunmaktadır.

2.1.1.2. Doğrusal hızlanma sensörü (Linear acceleration sensor)

Bu sensör yer çekimi etkisi olmadan sadece cihaza kullanıcının uyguladığı ivme değerini döndürmektedir.

2.1.1.3. Jiroskop sensörü (Gyroscope sensor)

Cihazın, üç fiziksel eksenin (x, y ve z) her biri etrafında açılma dönmesini algılayan cihaz sensörüdür. Cihazın mevcut yönünü ya da yön değişimini tespit etmede kullanılır. Geriye rad/s cinsinden sayısal değer döndürür.

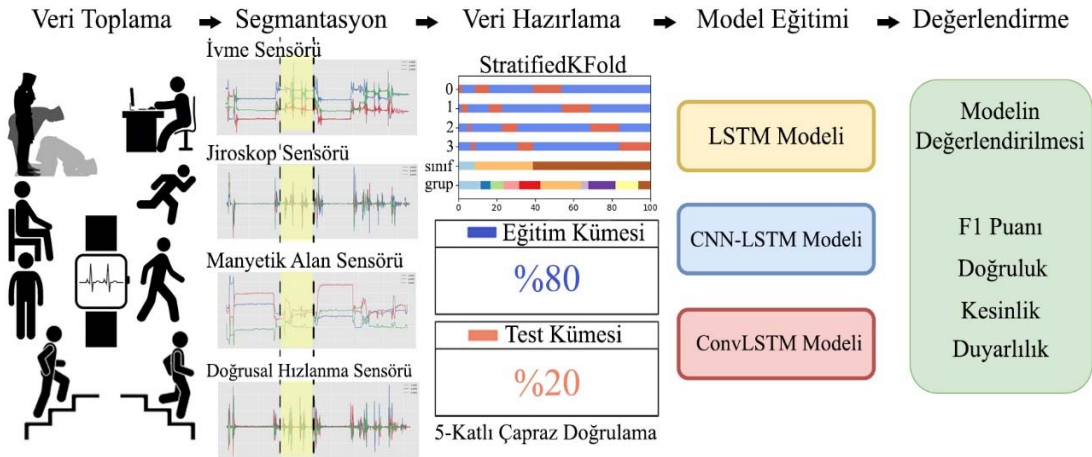
2.1.1.4. Manyetik alan sensörü (Magnetic field sensor)

Cihazın manyetik alanını ölçer. Veriler mikrottesla biriminden elde edilmektedir (μT) ve X, Y ve Z eksenlerinde -128 ile +128 arasında normalize edilmiştir. Cihaz tarafından gözlemlenen toplam manyetik alan, dünyanın jeomanyetik alanı ve cihazın kendi çevresindeki manyetik alanın toplamıdır.

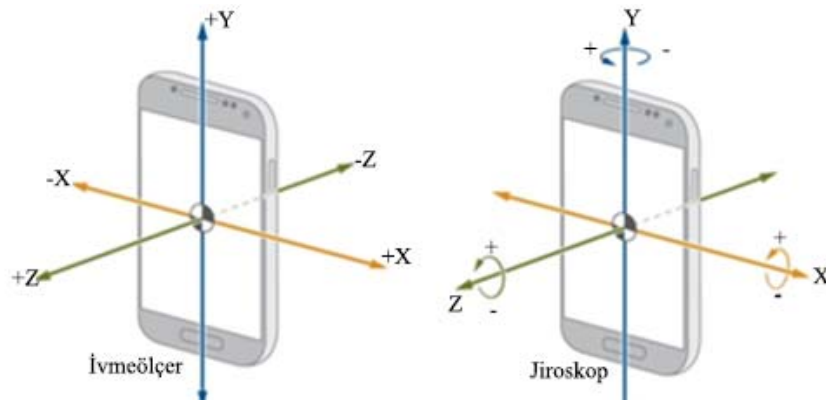
Şekil 2'de ivmeölçer ve jiroskop sensörüne ait üç eksen yön gösterimi görülmektedir.

2.1.2. Verinin Toplanması (Data collection)

HAR-P veri kümesi için 15-60 yaş aralığındaki gönüllü 50 farklı erkek bireyden veri toplanmıştır. Her bireyden tüm aktivitelere ait örnekler toplanmamıştır. Hangi bireylerden hangi aktivitelerin toplandığı Tablo 1'de gösterilmiştir. Veri toplamak için WearOS işletim sistemine sahip OPPO Watch akıllı saati kullanılmıştır. Veri toplama için kullanılan akıllı saat, kişinin tercihine bırakılarak istediği bileğine takılmıştır. Namaz kılma (Praying) eylemi için kullanıcılardan iki rekât namaz kılması istenilmiştir, bu aktivite için süre sınırlaması



Şekil 1. Çalışmanın Genel Görünümü: Metot ve Yöntemler (Overview of the Study: Methodology and Approach)



Şekil 2. Akıllı telefon üzerinde ivmeölçer ve jiroskop sensörlerine ait eksen gösterimi (Axis display of accelerometer and gyroscope sensors on smartphone)

yapılmamıştır. Bilgisayar klavyesi ile yazı yazma (Typing) eyleminde kullanıcılar sandalyeye oturmuş bir şekilde 1 dk. boyunca klavye ile yazı yazmışlardır. Yürüme (Walking) ve Koşma (Running) eylemleri yine bir dakika boyunca, düz bir zeminde gerçekleştirilmiştir. Oturma (Sitting) eyleminde kullanıcılar 1 dk. boyunca sandalyede oturmuşlardır. Ayakta durma (Standing) eyleminde kullanıcılar 1 dk. boyunca düz bir zeminde hareketsiz bir şekilde ayakta durmuşlardır. Merdiven inme (Downstairs) ve merdiven çıkma (Upstairs) eylemleri için kullanıcılar, 4 katlı bir binanın 55 basamak ve 40 adımlık kat arası düzlüklerden oluşan merdiveninde ortalama 45 saniye boyunca iniş ve çıkış yapmışlardır. Tablo 1’de ayrıntılı olarak gösterildiği üzere; Downstairs, Running, Sitting, Standing, Typing, Upstairs ve Walking aktiviteleri için 25 farklı kişiden örnek alınırken; Praying aktivitesi için 35 farklı kişiden örnek alınmıştır.

2.1.3. Veri toplama yazılımı (Data collection software)

Akıllı saatteki ham sensör verilerine erişmek, sensör verilerini akıllı saate kaydetmek ve akıllı saatten kaydedilmiş verileri akıllı telefona aktarmak için açık kaynak olarak paylaşılmış Sensorbox [41] mobil uygulaması kullanılmıştır. Sensorbox uygulamasının yüklenildiği cihazdaki tüm sensörlere “Home” ekranında listelenebilmektedir (Şekil 3a). Cihazdaki sensör listesinden seçilen sensöre ait özellikler “Sensor Information” ekranında görüntülenebilmektedir (Şekil 3b). Sensörlerden veri toplama sıklığı gibi bazı ayarlar “Options of measurement” ekranında belirlenebilmektedir (Şekil 3c). Seçilen sensöre ait veriler ekranda grafiksel olarak gösterilebilmektedir (Şekil 3d).

Akıllı telefona yüklenen Sensorbox uygulaması ile akıllı saatteki Sensorbox uygulaması yönetilebilmektedir. Sensörlerden verinin ne sıklıkla alınacağı ve verinin etiketlenmesi işlemleri akıllı telefon üzerindeki Sensorbox uygulaması ile yapılmıştır. HAR-P veri kümesi için veri toplanırken, kullanıcıların bileklerine akıllı saat takılmış, 8 aktiviteden hepsi/bazıları kullanıcılara yaptırılmış ve doğrusal hızlanma (acc), ivmeölçer (acg), jiroskop (gyro), manyetik alan (magnet) sensörlerine ait veriler kayıt altına alınmıştır. Kaydı alınan bu 4 sensör için akıllı saat hafızasında her ölçüm için “wear_acc.csv”, “wear_acg.csv”, “wear_gyro.csv”, “wear_magnet.csv” ve “extra.json” ile “wear_extra.json” dosyaları oluşmaktadır. “.csv” uzantılı dosyalar, adını aldığı sensöre ait verileri içerirken, “.json” uzantılı dosyalar ölçüm tarihi ve programın tercih edilen ayarlarını içermektedir.

2.1.4. Sensörlerden veri alma sıklığı (Frequency of receiving data from sensors)

Veri gecikmesi (veya örnekleme hızı), sensör olaylarının veri gönderme aralığını kontrol eder. Belirlenen gecikme önerilen bir

gecikme olup Android işletim sistemi, pil optimizasyonu ve güç tüketimi gibi nedenlerle bu gecikmeyi değiştirebilmektedir. Sensorbox uygulamasının veri alma kısmının belirlendiği ayarlar kısmında 4 seçenek bulunmaktadır: sensor_delay_normal (200.000 mikro saniye gecikme), sensor_delay_uı (60.000 mikro saniye gecikme), sensor_delay_game (20.000 mikro saniye gecikme), sensor_delay_fastest (0 mikro saniye gecikme). Bu dört seçenek Android 3.0’da (API Düzey 11) yer alan bir standarttır [42]. HAR-P veri kümesi için sensörlerden veri alma aşamasında bu seçeneklerden sensor_delay_uı (60.000 mikro saniye gecikme) kullanılmıştır. Kullanılan bu değer ile 1dk’lık veri toplama sonucunda 3200 veri elde edilmiş olup bu değer saniyede ortalama 54 veriyi içermektedir. (50 Hz/s).

2.1.5. Verinin etiketlenmesi (Labeling of data)

Veri etiketleme işlemi, bireylerden veri toplama aşamasında; kullanılan programda yer alan ve Şekil 3d’de gösterilen, “Add Annotation” butonu kullanılarak otomatik bir şekilde gerçekleştirilmiştir. Sensörlerden elde edilen ham veriler, hangi aktivite için toplandığını ifade edecek şekilde veri yapısına uygun halde yazdırılmıştır. Aktiviteler İngilizce isimleriyle adlandırılmıştır. Nihai veri kümesine ait örnek kayıtlar Şekil 4’teki gibidir.

```
Walking,171148007855773,8.984731,-3.842545,0.27148315
Walking,171148027387773,9.532316,-3.7134204,0.73776716
Walking,171148046918773,9.788175,-3.665596,1.1801392
Downstairs,10439259868481,10.247285,-4.3638263,-0.13502085
Downstairs,10439310649481,10.249676,-6.372434,0.5703832
Downstairs,10439331157481,9.36254,-5.640727,0.81667674
```

Şekil 4. HAR-P veri kümesinin bir kısmına ait ekran görüntüsü (Screenshot of part of the HAR-P dataset)

Şekil 4’te bir kısmı verilmiş HAR-P veri kümesinin, veri yapısının sütun başlıkları şu şekildedir: Aktivite, Zaman Damgası, X Eksen, Y Eksen, Z eksen. Buradaki ilk değer aktiviteyi, ikinci sütun zaman damgasını, son üç değer ise sensörden gelen 3 eksen değerini ifade etmektedir.

2.1.6. Veri kümesinin analizi (Analysis of dataset)

Veri toplanan kullanıcıların saati hangi koluna taktığı, boy, kilo ve yaş bilgileri ile hangi kullanıcıdan hangi aktiviteler için örnek toplandığı bilgisi Tablo 1’de yer almaktadır. Tablo 1’de görüldüğü üzere bazı kullanıcılardan 8 aktivite için de örnek alınırken bazılarında sadece



Şekil 3. Sensorbox uygulaması ekran görüntüleri (The Sensorbox app’s screens)

Tablo 1. Kullanıcı – Aktivite bilgisi (User – Activity information)

No	Kullanıcı Bilgileri					Aktiviteler							
	ID	Kol	Boy (cm)	Kilo (kg)	Yaş (Yıl)	Downstairs	Praying	Running	Sitting	Standing	Typing	Upstairs	Walking
1	311	SAĞ	170	71	15	✓	✓	✓	✓	✓	✓	✓	✓
2	312	SOL	165	45	16	✓	✓	✓	✓	✓	✓	✓	✓
3	313	SOL	140	45	15	✓	✓	✓	✓	✓	✓	✓	✓
4	314	SAĞ	177	67	16	✓	✓	✓	✓	✓	✓	✓	✓
5	315	SOL	168	52	16	✓	✓	✓	✓	✓	✓	✓	✓
6	316	SOL	170	65	16	✓	✓	✓	✓	✓	✓	✓	✓
7	317	SOL	172	55	16		✓		✓	✓	✓		✓
8	318	SOL	184	60	17	✓	✓	✓	✓	✓	✓	✓	✓
9	319	SAĞ	174	82	17		✓		✓	✓	✓		✓
10	320	SOL	172	77	20		✓		✓	✓	✓		✓
11	321	SOL	183	88	36	✓		✓	✓	✓	✓	✓	✓
12	322	SOL	175	55	15		✓		✓	✓	✓		✓
13	323	SAĞ	165	75	16				✓	✓	✓		✓
14	324	SOL	176	85	43		✓		✓	✓	✓		✓
15	325	SOL	172	100	50		✓		✓	✓			✓
16	326	SAĞ	174	72	16		✓		✓	✓	✓		✓
17	327	SOL	170	50	16	✓	✓	✓				✓	✓
18	328	SAĞ	165	52	17	✓		✓				✓	
19	329	SOL	150	50	15	✓		✓				✓	
20	330	SOL	159	78	17	✓		✓				✓	
21	331	SOL	160	45	15	✓		✓				✓	
22	332	SAĞ	174	55	16	✓	✓	✓				✓	✓
23	333	SOL	170	50	17	✓	✓	✓				✓	✓
24	334	SOL	160	52	17	✓	✓	✓				✓	
25	335	SAĞ	182	68	19	✓	✓	✓				✓	✓
26	336	SOL	160	51	15	✓		✓				✓	
27	337	SOL	182	65	17	✓		✓				✓	
28	338	SAĞ	170	68	17	✓		✓	✓	✓	✓	✓	✓
29	339	SAĞ	170	78	16	✓		✓	✓	✓	✓	✓	✓
30	340	SAĞ	166	51	17	✓	✓	✓		✓	✓	✓	✓
31	401	SOL	180	85	20		✓						
32	402	SOL	175	60	18		✓						
33	403	SOL	180	77	20		✓						
34	404	SAĞ	175	70	18		✓						
35	405	SOL	162	50	15		✓						
36	406	SAĞ	187	62	17		✓						
37	407	SAĞ	178	105	46		✓						
38	408	SAĞ	174	89	46		✓						
39	409	SAĞ	170	61	20		✓						
40	410	SOL	185	95	19		✓						
41	411	SOL	178	112	37				✓	✓	✓		✓
42	412	SOL	183	100	33				✓	✓	✓		✓
43	413	SOL	178	81	54		✓		✓	✓	✓		
44	414	SAĞ	178	81	59		✓		✓	✓	✓		
45	415	SAĞ	178	88	50		✓		✓	✓	✓		
46	416	SOL	175	106	59		✓		✓	✓	✓		
47	417	SAĞ	179	88	43		✓		✓	✓	✓		
48	418	SAĞ	169	67	18	✓		✓				✓	
49	419	SOL	166	52	16	✓		✓				✓	
50	420	SOL	180	75	22	✓		✓				✓	

1 aktiviteden örnek alınmıştır. Downstairs, Running, Sitting, Standing, Typing, Upstairs ve Walking aktiviteleri için 25 farklı kişiden örnek alınırken; HAR-P veri kümesinin geliştirilmesindeki amaç kullanıcının namaz kılma durumunu belirlemek olduğundan, Praying aktivitesi için 35 farklı kişiden örnekler alınmıştır. Tablo 2’de HAR-P veri kümesindeki dört sensör çeşidi verisine ait aktiviteye göre örnek sayıları ve yüzdelik değerleri görülmektedir. “Praying” aktivitesi için fazla sayıda kayıt yapılması (10 kişi) ve bu aktivite için süre sınırlandırması yapılmadan, 2 rekât namazı kişinin normal hızda


namaz kılması ile kayıt süresinin diğer aktivitelere göre fazla olmasıyla “Praying” aktivitesi dört veri setinde de ortalama % 45’lik çoğunluğa sahip olmuştur. Şekil 5’te ivme sensörüne ait veri setinin kullanıcılar göre kayıt sayısının dağılımı bulunmaktadır. Toplamda 50 kullanıcıdan toplanan örnek sayısında bir denge olmadığı görülmektedir. Bunun nedeni her kullanıcıdan tüm aktivitelere ait örnek toplanmamış olması ve “Praying” aktivitesinde zaman sınırlandırması yerine her bireyin iki rekât namazı normal hızlarında kılmalarıyla oluşan zaman farkından kaynaklanmaktadır.

HAR-P veri kümesindeki dört farklı sensörün aktivitelere göre örnek sayı dağılımı grafiği Şekil 6'daki gibidir. Veri toplama aşamasında tüm sensörlerden aynı örnekleme oranında veri toplanmış olmasına rağmen, sensörlerin donanımsal olarak veri gönderme oranları farklı olduğundan dört sensörden toplanan veri sayısı birbirinden farklı olmuştur. HAR-P veri kümesinde sekiz aktivite için örnek toplanan,

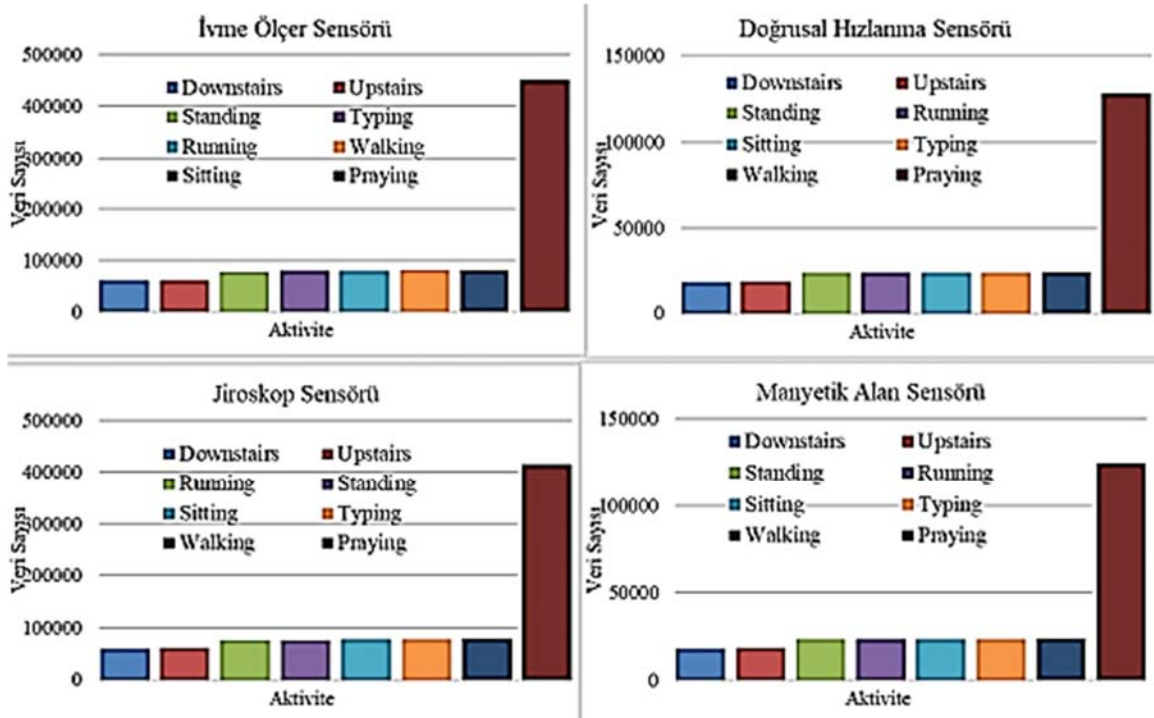
bir kişiye ait ivmeölçer sensör verilerinin zamansal grafiği Şekil 7'de görülmektedir. Her aktivitenin ilk 700 verisi grafiğe aktarılmış olup x-y-z eksen değerleri farklı renklerde gösterilmiştir. Böylece, "Sitting" ve "Standing" aktivitelerinin birbirine benzer grafik eğrilerine sahipken, grafikte eksenlerin yer değiştirdiği görülmektedir.

Tablo 2. Sensör – Aktivite kayıt sayıları ve yüzdeleri (Sensor – Activity log counts and percentages)

	Doğrusal Hızlanma Sensörü	İvme Sensörü	Jiroskop Sensörü	Manyetik Alan Sensörü
Downstairs	17987 ~ 6,4%	60955 ~ 6,28%	59701 ~ 6,45%	17954 ~ 6,47%
Praying	127114 ~ 45,24%	449985 ~ 46,35%	415092 ~ 44,87%	124155 ~ 44,72%
Running	23259 ~ 8,28%	79350 ~ 8,17%	77008 ~ 8,32%	23221 ~ 8,36%
Sitting	23414 ~ 8,33%	81362 ~ 8,38%	77687 ~ 8,4%	23348 ~ 8,41%
Standing	23231 ~ 8,27%	77409 ~ 7,97%	77157 ~ 8,34%	23210 ~ 8,36%
Typing	23647 ~ 8,42%	79317 ~ 8,17%	78221 ~ 8,46%	23516 ~ 8,47%
Upstairs	18369 ~ 6,54%	61517 ~ 6,34%	60795 ~ 6,57%	18325 ~ 6,6%
Walking	23959 ~ 8,53%	80845 ~ 8,33%	79448 ~ 8,59%	23924 ~ 8,62%
TOPLAM	280980 ~ 100%	970740 ~ 100%	925109 ~ 100%	277653 ~ 100%



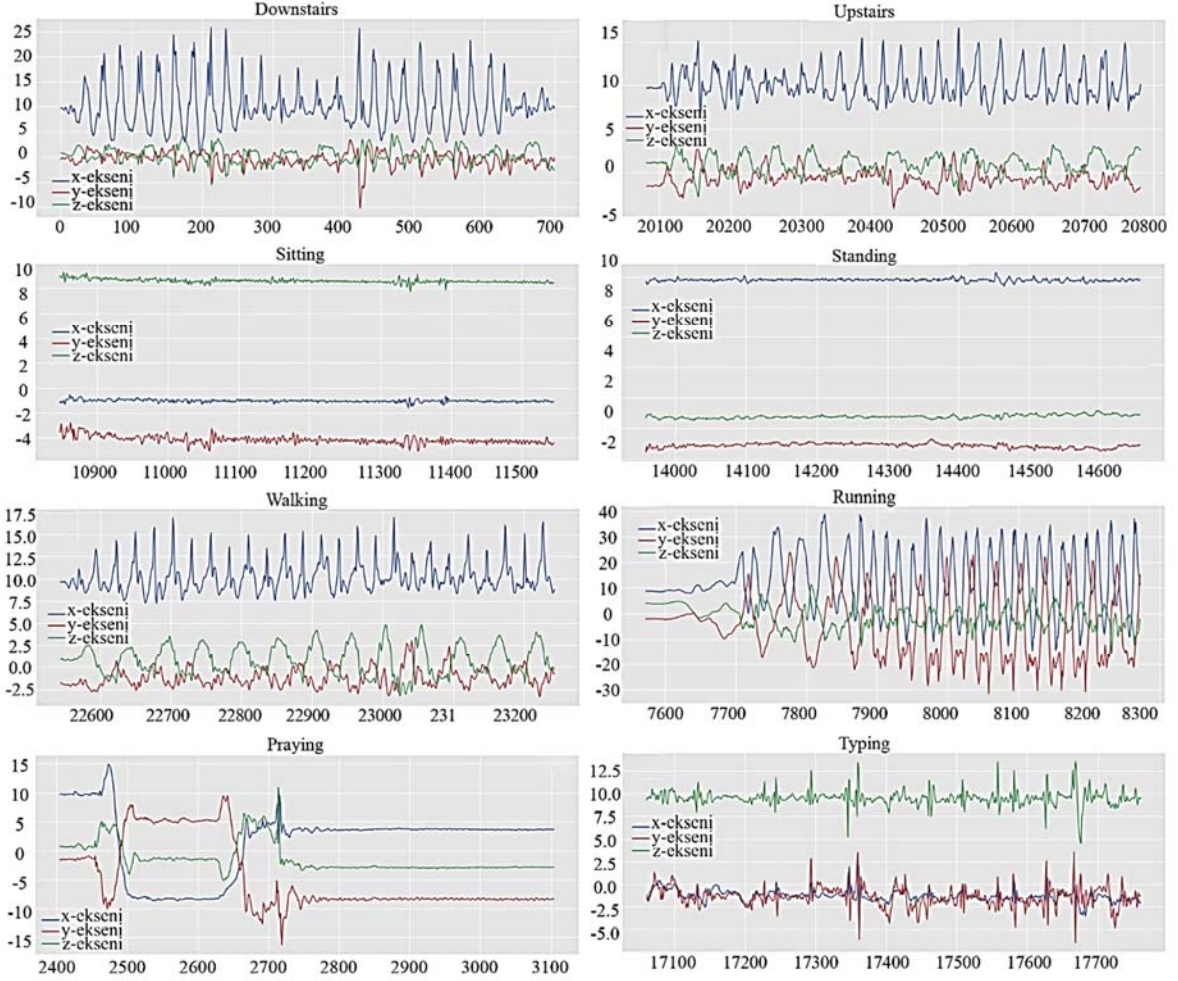
Şekil 5. İvme sensörüne ait verilerin kullanıcılara göre dağılımı (Distribution of data of the acceleration sensor by users)



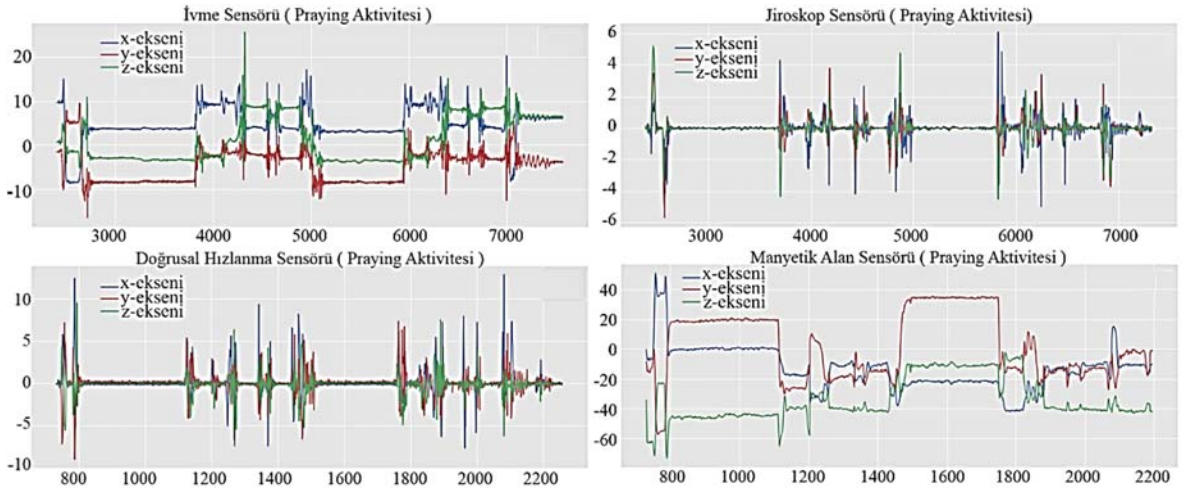
Şekil 6. Veri kümesindeki sensörlere ait veri grafikleri (Data graphs of sensors in the dataset)

HAR-P veri kümesinin geliştirilmesindeki asıl amaç namaz kılama eyleminin tespiti olduğundan "Praying" aktivitesi için ayrıca zaman-veri grafiği çıkarılmıştır. Örnek bir kayda ait dört sensör verisinin zaman-veri grafiği Şekil 8'deki gibidir. Bu grafikte veri sayısında sınırlandırmaya gidilmemiş olup, kullanıcının aktiviteyi gerçekleştirdiği süre boyunca sensörlerden toplanan ham veriler

grafiğe aktarılmıştır. Şekil 8'deki grafikler incelendiğinde, namaz kılama eyleminde bileğin vücutta sabit kaldığı zaman dilimlerinde, grafikte düzlükler oluşmaktadır. Şekil 8'deki ilk grafikte 2800-3800 ve 5000-6000 aralığındaki iki uzun düzlük, namazın bölümlerinden olan "Tekbir" sonrası ellerin göbekte bağlandığı anda oluşmaktadır. Bu aralıklardaki verilerin grafiği ile Şekil 7'deki "Standing"



Şekil 7. Örnek bir kaydın ivmeölçer sensör verisi grafiği (Accelerometer sensor data graph of a sample recording)



Şekil 8. Bir kullanıcıya ait namaz aktivite verisinin 4 sensör için grafikleri (Graphs of a user's prayer activity data for 4 sensors)

aktivitesinin grafiği benzerlik göstermektedir. Ayrıca yine Şekil 8'deki ilk grafiğin 4300-4500 ile 4600-4700 aralığındaki düzlükler namazın bölümlerinden olan "Secde" kısmında iken oluşmakta olup, bu kısımlar Şekil 7'deki "Sitting" aktivitesinin grafiğine benzerlik göstermektedir. Bunun nedeni karmaşık aktivite sınıfında yer alan "Praying" aktivitesinin içerisinde, basit aktivite türü olan "Sitting" ve "Standing" aktivitelerinin de yer almasıdır.

Veriye dayalı bir model geliştirmeden önce, veriyi tanımak için veri görselleştirilmesi yapılmaktadır. Çok boyutlu verileri görselleştirebilmek için verinin en fazla 3 boyuta indirilmesi gerekmektedir. Boyut indirgeme konusunda birçok yöntem bulunurken, veri görselleştirme konusunda t-SNE (t-Distributed Stochastic Neighbor Embedding) yöntemi [43] görsel açıdan daha iyi sonuçlar vermektedir. t-SNE yönteminde boyut indirilmesi yapılırken; benzer noktaları birbirine yakın, benzer olmayanları ise birbirinden uzak tutmaya çalışılmaktadır. HAR-P veri kümesindeki, ivme sensörüne ait tüm verilerin t-SNE yöntemi ile görselleştirilmesinin sonucu, Şekil 9'da görülmektedir.

Şekil 9'da "Downstairs" ve "Upstairs" aktivitelerini ifade eden renklerin birbiri içerisine geçtiği görülmektedir. Bunun nedeni, bu iki aktivitenin birbirine çok benzemesidir. Turuncu renkle gösterilen "Running" ifadesi, "Downstairs" ve "Upstairs" aktivitelerini kapsayarak; yine birbiri içerisine geçmiştir. Bu üç aktivite, yürüme eylemi ile yapıldığından; "Walking" aktivitesini ifade eden sarı renk, bu üç aktiviteye ait renklerin altında kalmıştır. "Sitting" aktivitesini belirten kırmızı renk ve "Standing" aktivitesini belirten mavi renk, belirgin gruplaşmalar yaparak örnek uzayda yer almıştır. Siyah renkle gösterilen "Typing" aktivitesi diğer renklerden ayrılarak gruplaşmış bir şekilde "Sitting" aktivitesine yakın bölgelerde yer almıştır. Yeşil renkle gösterilen "Praying" aktivitesi, diğer aktiviteleri kapsayacak şekilde örnek uzayda her yere dağılmıştır. Bunun nedeni, "Praying" aktivitesinin kendi içerisinde "Sitting" ve "Standing" aktivitelerini de barındırmasıdır. Şekil 9'daki gibi örnek uzayda birbirine karışmış renklerin bulunması, HAR-P veri kümesinde sınıflandırma yapmanın zorluğunu belgelemektedir.

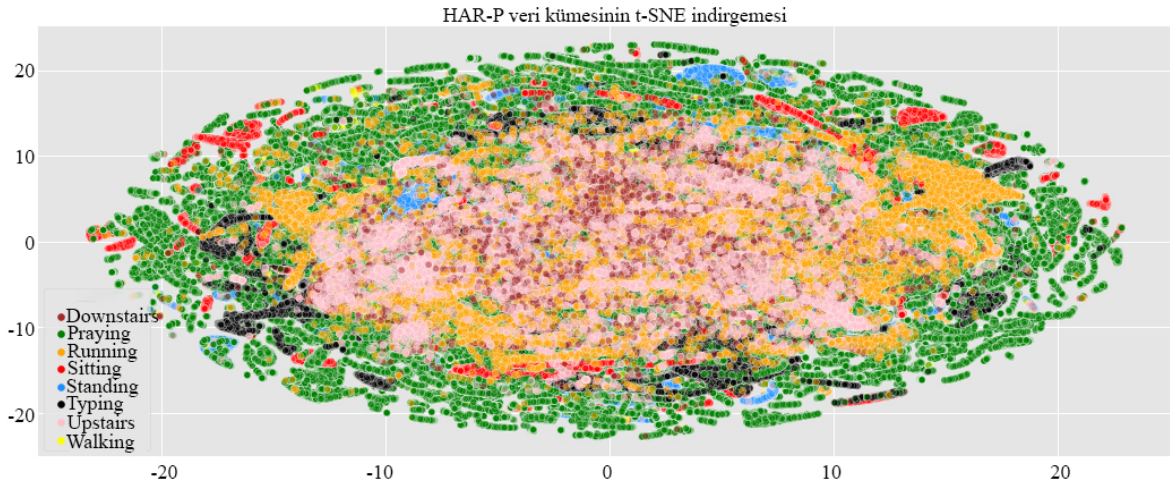
2.2. İnsan Aktivitelerinin Derin Öğrenme Modelleriyle Sınıflandırılması

(Classification of Human Activities with Deep Learning Models)

Bu bölümde LSTM, ConvLSTM ve CNN-LSTM ağ modelleri ile HAR-P veri kümesinin sınıflandırılması gerçekleştirilmiş ve başarı durumları karşılaştırılmıştır. Sensör verilerinden oluşan zaman

serilerinin analiz edilmesinde, LSTM modelinin, öznetelik çıkarma sürecinde uzman bilgisi gerektirmeyen otomatik işlemlerle yüksek başarı sağladığı bilinmektedir. LSTM, zaman serileri verilerini işlemek ve zaman içindeki ilişkileri modellemek için etkili bir şekilde kullanılmaktadır. CNN-LSTM, hem mekânsal hem de zamansal özelliklerin bir arada ele alınması gerektiği durumlarda avantaj sağlayan bir yapıya sahiptir. ConvLSTM ise hem mekânsal hem de zamansal ilişkileri aynı anda ele almak için tasarlanmıştır ve bu özelliğiyle sensör verileri gibi hem zamansal hem de mekânsal bilgiler içeren veri setlerinde etkili olabilir. Bu üç modelin seçilmesinin temel nedeni, sensör verileri üzerindeki işlem gereksinimlerine ve veri yapısına uygun olmasıdır.

Zaman serisi analizinde giriş verileri, belirli pencere boyutlarında işleme tabi tutulmaktadır. Bu çalışmada farklı pencere boyutları ile testler gerçekleştirilmiştir. Her yöntem için ortalama en yüksek doğruluk değeri veren ortak çerçeve boyutu bulunmaya çalışılmıştır. Optimum çerçeve boyutu olarak 200 değerine ulaşılmıştır. Bu 200 değeri, saniyede ortalama 50 veriden, 4 sn'lik pencere boyutuna denk gelmektedir. Her satırda sensörden gelen 3 eksen verisi ile giriş veri boyutu $200 \times 3 = 600$ olmaktadır. Bu girdi boyutu, her modelin yapısına uygun şekilde yeniden boyutlanmaktadır. Sensör çeşidinin sınıflandırmaya etkisini belirlemek adına her sensör veri kümesi, ayrı ayrı belirlenen 3 model için test edilmiştir. HAR-P veri kümesinde sınıfların dağılımının dengesizdir (Praying %45, diğerleri ortalama %8). Bir veri kümesini, eğitim ve test alt kümelerine bölerken, veri kümesindeki farklı sınıfların oranını korumak için Python'da yer alan Stratify (katmanlaştırma) işlevi kullanılmaktadır. Makine öğrenimi modellerinin performansını değerlendirmek için k-katlı çapraz doğrulama yapılmaktadır. Bu makalede, k katlı çapraz doğrulama yöntemlerinden, sınıf dağılımını dengeleyerek testlerin yapıldığı, scikit-learn kütüphanesinde yer alan StratifiedKFold fonksiyonu kullanılmıştır [44]. Veri kümesi 5 eşit parçaya bölünüp 4 parçası eğitim, 1 parçası test kümesi ve her 5 parça sırayla test kümesi olacak şekilde testler gerçekleştirilmiştir. Böylece veri kümesindeki tüm veriler hem eğitim hem de test kümesinde yer almıştır. Her model ve veri kümesi için yapılan test sonuçlarının; Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall) ve F1 Puanı (F1 Score) değerlerinin ortalamaları raporlanmıştır. Modelin eğitimi aşamasında, eğitim verilerinin modele kaç kez gösterileceğini epok (epoch) sayısı ifade etmektedir. Modelin aşırı öğrenmesi veya az öğrenmesini epok sayısı belirlediğinden, epok sayısının değerinin belirlenmesi önem arz etmektedir. Modelin gelişimini tamamladığı anda epok sayısına bakılmaksızın eğitimin durdurulmasında erken durdurma denilmektedir. Bu çalışmada erken durdurma yöntemi kullanılmış



Şekil 9. İvmeölçer sensör verilerinin t-SNE indirilmesi (t-sne reduction of acceleration sensor data)

olup, en uygun erken durdurma parametrelerinin belirlenmesi için denemeler yapılmıştır. Bu çalışma için erken durdurmada “doğrulama kaybı” (validation loss) değerine bakılarak, ConvLSTM yöntemi için 50 epok, LSTM ve CNN-LSTM yöntemleri için 30 epok ileme olmadığında eğitim durdurulması için parametreler ayarlanmıştır. 150 epok için test sonuçları incelendiğinde erken durdurma ile epok sayısının 31 ile 101 değerleri arasında olduğu gözlemlenmiştir. Her model için ortak olan diğer bir parametre ise modelin eğitim aşamasında ağı verilen alt örnek sayısını ifade eden toplu giriş boyutu (batch size) değeridir. Yapılan denemeler sonucunda en uygun toplu giriş boyutu değeri olarak, LSTM ve CNN-LSTM yöntemi için 32 ve ConvLSTM 128 olarak belirlenmiştir. Sınıflandırıcıların değerlendirme metrikleri olarak F1 puanı (F1 score), hassasiyet (precision) ve anımsama (recall) kullanılmıştır.

2.2.1. LSTM ağı modeli (LSTM network)

LSTM ağı modeli, uzun giriş verisi dizileri (long-sequence) üzerinden öğrenebilen ve hatırlayabilen bir tür tekrarlayan sinir ağıdır (RNN). RNN mimarisinin ardışık uzun veri kümelerindeki kaybolan gradyanlar probleminde çözüm olmak üzere önerilmiştir [45]. LSTM, RNN’deki tekrar eden hücrelerin içyapısındaki tanh katmanı yerine unutmaya kapısı (forget gate), girdi kapısı (input gate), çıktı kapısı (output gate) ve hücre durumu (cell state) olmak üzere 4 katman içermektedir. LSTM’deki hücre durumu (cell state) sayesinde önceki zamandan gelen bilgi (t-1), bir sonraki katmana iletelebilmektedir. Taşınacak bilgiyi ise kapıların durumu belirlemektedir. Kullanılan LSTM ağı modelinin yapısı Şekil 10’deki gibidir. Veri kümesinde, her satırda x, y, z eksenini ifade eden 3 değer için 200 satırlık veri boyutlaması yapılarak (200,3) tek katmanlı 1 adet LSTM ağına gönderilmektedir. LSTM katmanından, 0,5 değerine sahip seyreltme (dropout) katmanı ve 2 adet yoğun (dense) katmanı takip etmektedir. Son yoğun katmandaki 8 değeri, sınıf sayısını ifade

etmektedir. Çalışmamızda model parametreleri nöron sayısı 100, yoğun katman nöron sayısı 100 ve seyreltme değeri 0,5 olarak alınmıştır.

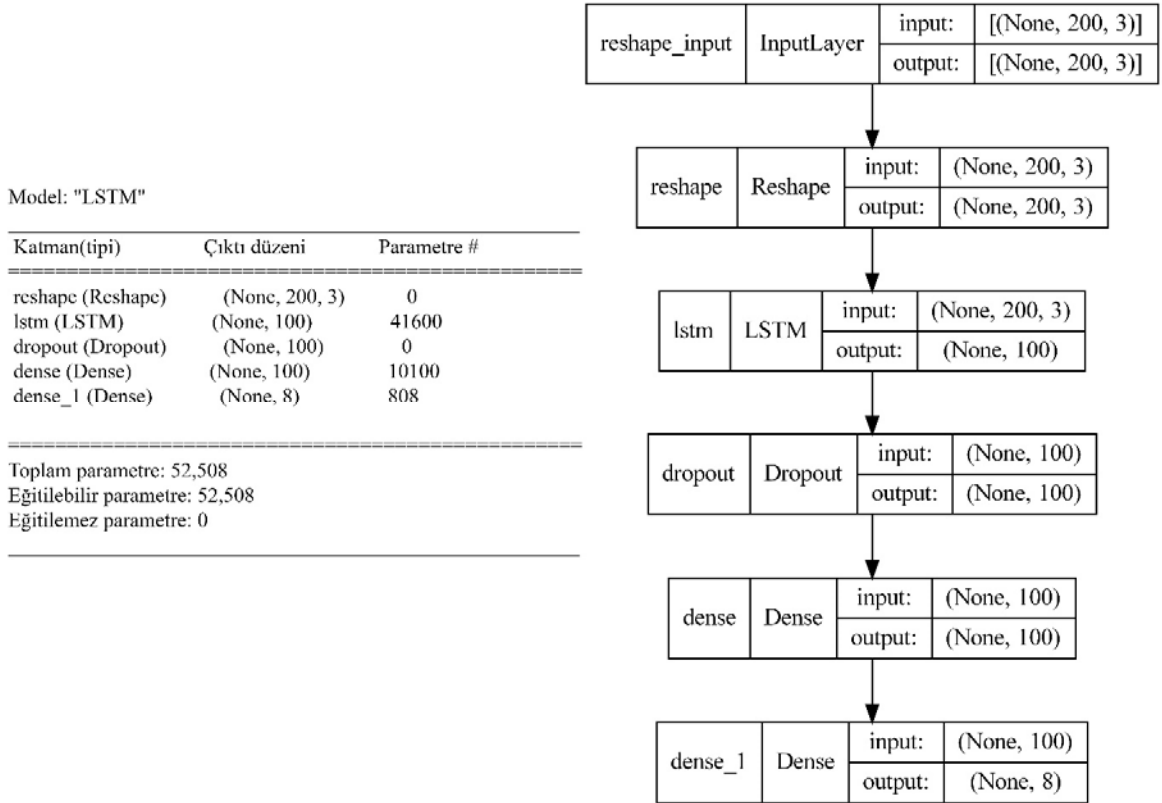
LSTM modelinin HAR-P veri kümesinde, farklı çerçeve boyutuna göre test sonuçlarından elde edilen doğruluk (accuracy) değerleri Tablo 3’te gösterilmiştir. Tablodaki “timestep” ifadesi, her pencerede bulunan satır sayısını ifade etmektedir. Sonraki pencereyi elde etmek için, veri kümesinde kaç kayıt kaydırma yapılacağını tablodaki “step” terimi ifade etmektedir. Veri kümesi, “timestep” sayısına kayıt okuyarak, modele giriş verisi olarak vermekte, “step” sayısı kadar sonraki veriye geçtikten sonra yine “timestep” sayısı kadar veriyi alarak modele vermeye devam eder. Bu şekilde tüm veriler işlenene kadar, pencere kaydırma işlemi devam etmektedir.

LSTM modeli için (200,10) çerçeve boyutlandırmasına göre ayrıntılı test sonuçları Tablo 4’teki gibidir. Buradaki değerler, 5 kat çapraz doğrulama sonucu oluşan değerlerin ortalaması alınarak oluşturulmuştur.

LSTM modelinde dört sensör çeşidi için yapılan test sonuçlarından elde edilen karmaşıklık matrisi Şekil 11’de görülmektedir. Buradaki karmaşıklık matrisleri, 5 kat çapraz doğrulamanın, ilk katına ait karmaşıklık matrisleridir.

2.2.2. ConvLSTM ağı modeli (ConvLSTM network)

Evrişimsel LSTM veya kısaca ConvLSTM olarak tanımlanan model, LSTM modelinin bir varyantıdır. ConvLSTM’de, LSTM’in hücre içyapısındaki dâhili matris çarpımları yerine evrişim (konvolüsyon) işlemleri gerçekleştirilir. ConvLSTM ağı modelinde, bir hücrenin girişleri ve geçmiş durumları ile yerel komşularının gelecekteki durumu belirlenmektedir [46]. Kullanılan ConvLSTM modelinin ağı



Şekil 10. Kullanılan LSTM ağı modeli yapısı (Structure of the LSTM network model used)

Tablo 3. LSTM modeli test sonuçları (LSTM model test results)

LSTM MODELİ				
	BatchSize	TimeStep	Step	Accuracy
İvme Sensörü (HAR-P ACG)	32	200	10	0,898
	32	200	20	0,861
	32	400	20	0,852
	32	500	20	0,828
	32	300	20	0,871
Doğrusal Hızlanma Sensörü (HAR-P ACC)	32	200	10	0,91
	32	200	20	0,857
	32	400	20	0,811
	32	500	20	0,807
	32	300	20	0,864
Jiroskop Sensörü (HAR-P Gyro)	32	200	10	0,844
	32	200	20	0,779
	32	400	20	0,717
	32	500	20	0,821
	32	300	20	0,81
Manyetik Alan Sensörü (HAR-P Magnet)	32	200	10	0,854
	30	200	20	0,771
	32	400	20	0,766
	32	500	200	0,768
	32	300	20	0,763

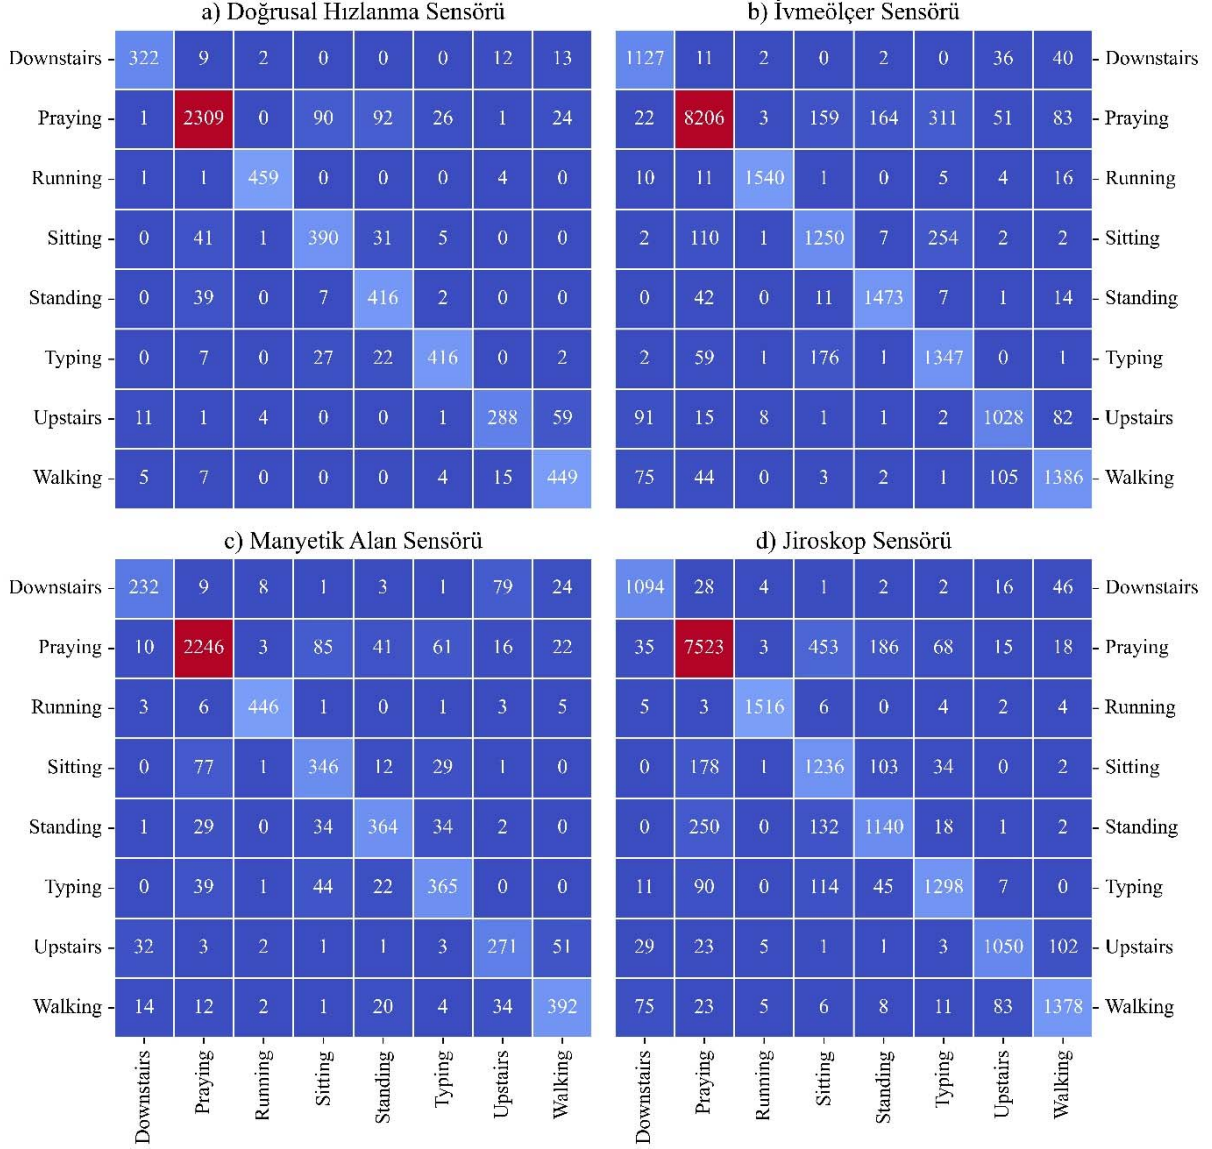
Tablo 4. LSTM modeli ayrıntılı test sonuçları (LSTM model detailed test results)

a) Doğrusal Hızlanma Sensörü				b) İvme Sensörü			
	Kesinlik	Duyarlılık	F1-puanı		Kesinlik	Duyarlılık	F1-puanı
Downstairs	0,924	0,932	0,928	Downstairs	0,904	0,916	0,908
Praying	0,964	0,908	0,932	Praying	0,962	0,916	0,938
Running	0,98	0,986	0,984	Running	0,992	0,974	0,982
Sitting	0,76	0,846	0,8	Sitting	0,774	0,758	0,766
Standing	0,782	0,902	0,834	Standing	0,888	0,952	0,922
Typing	0,894	0,916	0,906	Typing	0,724	0,858	0,786
Upstairs	0,902	0,868	0,884	Upstairs	0,84	0,858	0,848
Walking	0,882	0,91	0,892	Walking	0,862	0,884	0,874
Doğruluk			0,91	Doğruluk			0,898
Ağırlıksız Ortalama	0,886	0,908	0,894	Ağırlıksız Ortalama	0,87	0,886	0,878
Ağırlıklı Ortalama	0,914	0,91	0,91	Ağırlıklı Ortalama	0,906	0,898	0,9
c) Manyetik Alan Sensörü				d) Jiroskop Sensörü			
	Kesinlik	Duyarlılık	F1-puanı		Kesinlik	Duyarlılık	F1-puanı
Downstairs	0,78	0,72	0,746	Downstairs	0,882	0,896	0,888
Praying	0,932	0,918	0,926	Praying	0,87	0,91	0,886
Running	0,948	0,956	0,95	Running	0,99	0,98	0,986
Sitting	0,718	0,756	0,738	Sitting	0,548	0,506	0,482
Standing	0,754	0,792	0,772	Standing	0,706	0,64	0,662
Typing	0,82	0,758	0,786	Typing	0,86	0,81	0,832
Upstairs	0,768	0,734	0,744	Upstairs	0,858	0,868	0,862
Walking	0,78	0,852	0,816	Walking	0,86	0,864	0,862
Doğruluk			0,854	Doğruluk			0,844
Ağırlıksız Ortalama	0,81	0,812	0,808	Ağırlıksız Ortalama	0,822	0,808	0,808
Ağırlıklı Ortalama	0,858	0,854	0,854	Ağırlıklı Ortalama	0,834	0,844	0,836

yapısı Şekil 12'deki gibidir. Keras kütüphanesinde ConvLSTM modeli giriş verisi olarak 2 boyutlu bir yapı beklemektedir. LSTM modelinde kullandığımız (200,3) giriş veri boyutunu, ConvLSTM modelinde (200,20,10,3) şeklinde yeniden boyutlandırarak 2 boyutlu ConvLSTM ağına girdi olarak verilmektedir. ConvLSTM katmanını, seyreltme katmanı, düzleştirme (flatten) katmanı ve 2 adet yoğun (dense) katmanı takip etmektedir.

ConvLSTM modelinin HAR-P veri kümesinde, farklı çerçeve boyutuna göre test sonuçlarından elde edilen doğruluk (accuracy) değerleri Tablo 5'te gösterilmiştir. LSTM modelinden farklı olarak ConvLSTM ve CNN-LSTM modellerinde "nStep" ve "nLenght" parametreleri bulunmaktadır. Bu parametreler modellerin talep ettiği giriş veri boyutunu ayarlamak için kullanılmaktadır. Uygulamamızdaki (200,3) giriş veri boyutundaki 200 değeri, 20x10

LSTM Modeli Test Sonuçları



Şekil 11. LSTM modeli için karmaşıklık matrisi (Confusion matrix for the LSTM model)

(nStep, nLength) şeklinde modelin talep ettiği üzere 2 boyutlu hale getirilir.

ConvLSTM modelinin 200 timestep ve 10 step, çerçeve boyutlandırmasına göre ayrıntılı test sonuçları Tablo 6'daki gibidir. Buradaki değerler, 5 kat çapraz doğrulama sonucu oluşan değerlerin ortalaması alınarak oluşturulmuştur.

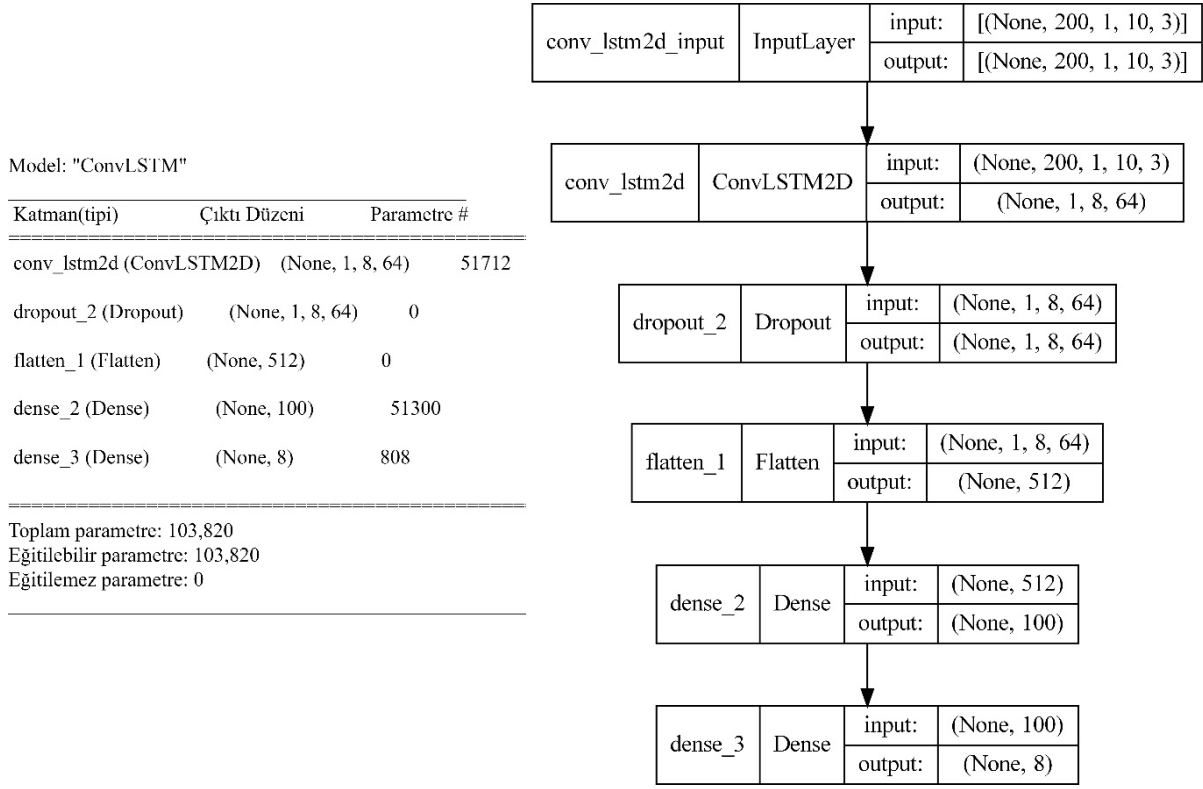
ConvLSTM modelinde dört sensör çeşidi için yapılan test sonuçlarından elde edilen karmaşıklık matrisi Şekil 13'te görülmektedir. Buradaki karmaşıklık matrisleri, 5 kat çapraz doğrulamanın, ilk katına ait karmaşıklık matrisleridir.

2.2.3. CNN-LSTM ağ modeli (CNN-LSTM network)

CNN-LSTM hibrid mimarisi, zaman serisi tahmininde kullanılan LSTM modelinin girişine, girdi verilerinde özellik çıkarımı için Evrişimsel Sinir Ağı (CNN) katmanlarının kullanılmasını sağlayan

yapıdır. CNN-LSTM modeli, veriyi bloklar halinde okuyarak, her bloktan öznelikleri çıkarmakta ve ardından LSTM'in her bir bloktan çıkarılan öznelikleri yorumlamasını sağlamaktadır. LSTM modelinde girdi olarak kullanılan (200,3) veri yapısı, CNN-LSTM modelinde 20 adet blok ve her blokta 10 satır veri olacak şekilde kullanılmıştır(20*10*3). Kullanılan ağ modelinin yapısı Şekil 14'te yer almaktadır. CNN-LSTM ağ modelinde, giriş katmanı ardından 2 adet 1 boyutlu konvolüsyon katmanı (Conv1D) art arda eklenmiş, ardından seyreltme ve havuzlama katmanı (MaxPooling) eklenmiştir. Düzleştirme katmanı ile CNN yapısı tamamlandı LSTM modelinin girişine verilmiştir. Konvolüsyon katmanlarında filtre sayısı 64, çekirdek sayısı 3, aktivasyon fonksiyonu olarak da 'ReLU' tercih edilmiştir.

CNN-LSTM modelinin HAR-P veri kümesinde, farklı çerçeve boyutuna göre test sonuçlarından elde edilen doğruluk (accuracy) değerleri Tablo 7'de gösterilmiştir. Tablo 7 incelendiğinde (400,20) ve (300,20) çerçeve boyutlandırmasında nispeten daha yüksek



Şekil 12. Kullanılan ConvLSTM ağ modeli yapısı (ConvLSTM network model structure used)

Tablo 5. ConvLSTM modeli test sonuçları (ConvLSTM model test results)

ConvLSTM Modeli	BatchSize	TimeStep	Step	nStep	nLenght	Doğruluk
İvme Sensörü (HAR-P ACG)	128	300	20	15	20	0,905
	128	200	10	10	20	0,91
	128	200	20	10	20	0,883
Doğrusal Hızlanma Sensörü (HAR-P ACC)	128	300	20	15	20	0,896
	128	200	10	10	20	0,894
	128	200	20	10	20	0,876
Jiroskop Sensörü (HAR-P Gyro)	128	300	20	15	20	0,839
	128	200	10	10	20	0,836
	128	200	20	10	20	0,793
Manyetik Alan Sensörü (HAR-P Magnet)	128	300	20	15	20	0,658
	128	200	10	10	20	0,876
	128	200	20	10	20	0,833

doğruluk (accuracy) değeri elde edilmesine rağmen, 3 modelin başarısını karşılaştırmak adına, en uygun ortak çerçeve boyutu (200,10) olarak belirlenmiştir.

CNN-LSTM modelinin (200,10) çerçeve boyutlandırmasına göre ayrıntılı test sonuçları Tablo 8'deki gibidir. Buradaki değerler, 5 kat çapraz doğrulama sonucu oluşan değerlerin ortalaması alınarak oluşturulmuştur.

CNN-LSTM modelinde dört sensör çeşidi için yapılan test sonuçlarından elde edilen karmaşıklık matrisi Şekil 15'te

görülmektedir. Buradaki karmaşıklık matrisleri, 5 kat çapraz doğrulamanın, ilk katına ait karmaşıklık matrisleridir.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu çalışmada akıllı saat kullanılarak elde edilen ivmeölçer sensörü, doğrusal hızlanma sensörü, manyetik alan sensörü ve jiroskop sensörü verileri ile yeni bir insan aktivite veri kümesi oluşturulmuştur. Yeni oluşturulan bu HAR-P isimli veri kümesinde derin öğrenme yöntemlerinden LSTM, ConvLSTM ve CNN-LSTM modelleri ile sınıflandırma çalışması yapılmış ve sensör çeşidi ve yöntemlerin

başarı durumu karşılaştırılmıştır. Bileğe takılı olan akıllı saatten elde edilen sensör verileri ile yapılan insan aktivitesinin tespit edilebileceği

görülmüştür. Yapılan insan aktivitesi sınıflandırmasında üç model de dört veri kümesi için birbirine yakın sonuçlar vermiştir. Ortalama en

ConvLSTM Modeli Test Sonuçları

a) Doğrusal Hızlanma Sensörü								b) İvmeölçer Sensörü								
Downstairs	349	1	5	0	0	0	1	2	1135	14	7	1	0	1	23	37
Praying	10	2205	3	133	129	41	5	17	7	8345	0	272	149	181	12	34
Running	1	0	463	0	0	0	1	0	16	8	1543	3	0	0	10	7
Sitting	0	37	4	364	48	14	1	0	1	107	1	1409	8	98	1	3
Standing	0	23	0	12	420	10	0	0	0	43	0	12	1490	0	3	0
Typing	0	7	0	26	17	419	3	1	0	136	0	179	4	1262	1	4
Upstairs	34	2	15	0	0	1	286	27	38	24	2	1	5	0	1102	56
Walking	11	9	0	0	2	5	50	402	39	45	0	1	5	1	54	1471

c) Manyetik Alan Sensörü								d) Jiroskop Sensörü								
Downstairs	299	8	6	0	1	1	8	35	1062	39	4	1	1	2	16	68
Praying	10	2363	3	41	26	7	9	25	26	7700	21	273	82	133	23	44
Running	1	1	455	2	0	0	5	0	5	10	1516	3	0	0	4	2
Sitting	1	87	1	327	38	8	0	5	0	614	1	771	90	72	1	5
Standing	2	35	0	6	417	3	0	1	4	598	0	161	755	23	0	3
Typing	0	85	0	60	5	316	1	3	1	145	1	70	13	1333	0	1
Upstairs	5	0	1	0	0	0	347	11	56	18	8	0	1	4	1038	89
Walking	14	10	3	0	20	2	24	406	80	56	0	1	3	9	92	1347

Şekil 13. ConvLSTM Modeli için Karmaşıklık Matrisi (Confusion Matrix for the ConvLSTM Model)

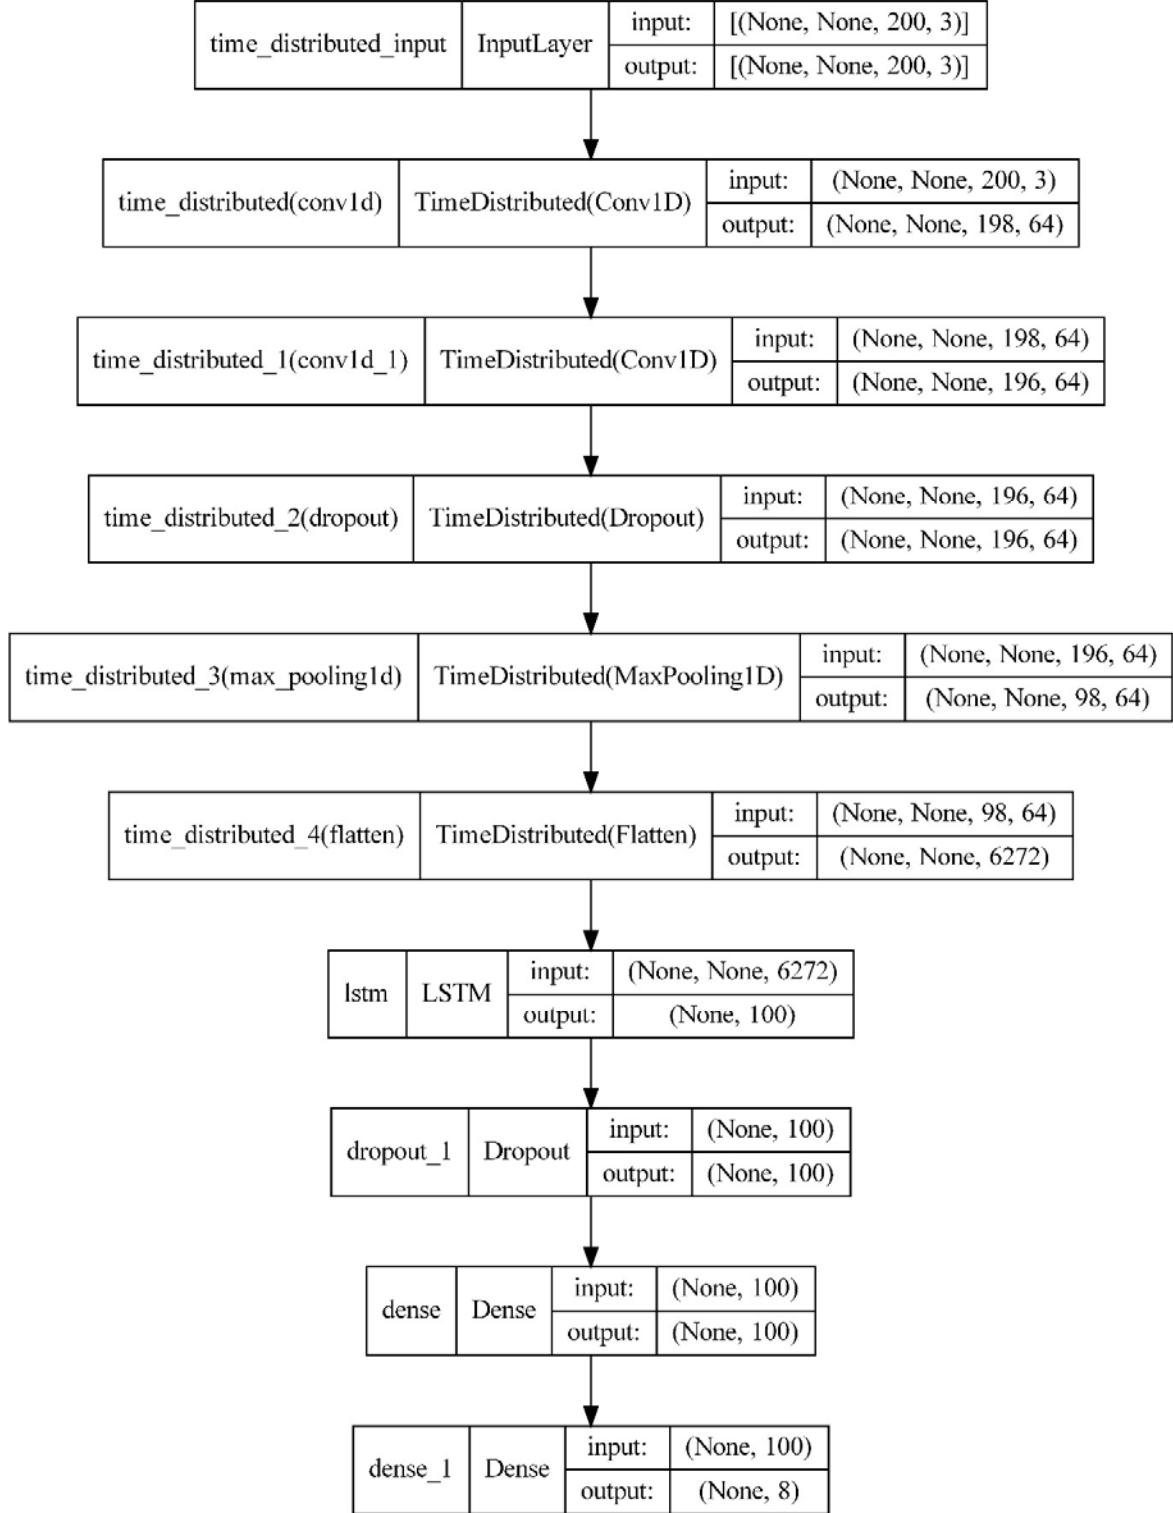
Tablo 6. ConvLSTM modeli test sonuçları (ConvLSTM model test results)

a) Doğrusal Hızlanma Sensörü				b) İvme Sensörü			
	Kesinlik	Duyarlılık	F1-puanı		Kesinlik	Duyarlılık	F1-puanı
Downstairs	0,902	0,936	0,916	Downstairs	0,93	0,922	0,928
Praying	0,954	0,902	0,926	Praying	0,95	0,924	0,938
Running	0,968	0,988	0,978	Running	0,988	0,98	0,984
Sitting	0,752	0,798	0,776	Sitting	0,76	0,816	0,786
Standing	0,768	0,866	0,812	Standing	0,89	0,96	0,922
Typing	0,856	0,91	0,884	Typing	0,816	0,83	0,822
Upstairs	0,87	0,874	0,872	Upstairs	0,896	0,888	0,894
Walking	0,892	0,876	0,884	Walking	0,894	0,904	0,896
Doğruluk			0,894	Doğruluk			0,91
Ağırlıksız Ortalama	0,87	0,894	0,882	Ağırlıksız Ortalama	0,892	0,904	0,898
Ağırlıklı Ortalama	0,902	0,894	0,898	Ağırlıklı Ortalama	0,912	0,91	0,912

c) Manyetik Alan Sensörü				d) Jiroskop Sensörü			
	Kesinlik	Duyarlılık	F1-puanı		Kesinlik	Duyarlılık	F1-puanı
Downstairs	0,854	0,846	0,852	Downstairs	0,878	0,868	0,874
Praying	0,926	0,92	0,924	Praying	0,868	0,888	0,876
Running	0,956	0,952	0,956	Running	0,976	0,986	0,98
Sitting	0,758	0,672	0,71	Sitting	0,572	0,564	0,566
Standing	0,784	0,898	0,838	Standing	0,71	0,616	0,652
Typing	0,852	0,742	0,79	Typing	0,832	0,836	0,836
Upstairs	0,9	0,926	0,914	Upstairs	0,858	0,872	0,862
Walking	0,78	0,842	0,806	Walking	0,862	0,86	0,86
Doğruluk			0,876	Doğruluk			0,836
Ağırlıksız Ortalama	0,854	0,848	0,848	Ağırlıksız Ortalama	0,818	0,81	0,814
Ağırlıklı Ortalama	0,878	0,876	0,876	Ağırlıklı Ortalama	0,836	0,836	0,836

yüksek başarı oranı olan %91'e doğrusal hızlanma sensörü ile LSTM yöntemi ve ivme sensörü ile ConvLSTM modelinde ulaşılırken, en düşük ortalama başarı oranı olan %83.6'a jiroskop sensörü ve ConvLSTM yöntemi ile ulaşılmıştır. HAR-P veri kümesinde bulunan sekiz aktiviteden en yüksek f1 puanına (0.986, f1-score) CNN-LSTM modeli kullanılarak ivme sensörü ile "Running" aktivitesi için

ulaşılmıştır. Bu çalışmanın esas amacı olan "Praying" aktivitesinin sınıflandırılmasında en yüksek f1 puanına (0.938, f1 score) ivmeölçer sensörü ile ConvLSTM ve LSTM modelleri ile ulaşılmıştır. Karmaşıklık matrisleri incelendiğinde "Praying" aktivitesi, en çok "Sitting", "Standing" ve "Typing" aktiviteleri ile karıştırılmıştır. Bunun nedeni ise "Praying" aktivitesinin "Sitting" ve "Standing"



Şekil 14. Kullanılan CNN-LSTM ağ modeli yapısı (CNN-LSTM network model structure used)

aktivitelerini içermesi ve “Typing” aktivitesinin oturularak (Sitting) yapılan bir aktivite olmasıdır.

Tablo 2 incelendiğinde, jiroskop sensörü veri sayısı (925109) ile ivme sensörü veri sayısı birbirine (970740) yakın iken, ivme sensörü kullanılarak yapılan sınıflandırmada başarı daha yüksektir. Yine Tablo 2’de doğrusal hızlanma sensörü veri sayısı (280980) ile manyetik alan sensör veri sayısı (277653) birbirine yakın iken, doğrusal hızlanma sensörü ile yapılan sınıflandırma işleminin başarısı nispeten daha iyidir. İvmeölçer sensörü ve doğrusal hızlanma sensörü,

insan aktivite sınıflandırmasında; manyetik alan sensörü ile jiroskop sensörüne göre daha başarılı sonuçlar vermiştir. İvmeölçer sensörü veri sayısı (970740), doğrusal hızlanma sensörü veri sayısının (280980) yaklaşık 3.45 katı olmasına rağmen, başarı oranında fazla bir fark oluşmamıştır. Buradan veri sayısının belirli bir noktadan sonra fark oluşturmadığına, kullanılan sensör ve yöntemin daha önemli olduğu sonucuna ulaşabiliriz.

Gerçek ortamda kullanıcıların telefonu taşıma yerleri ve şekilleri farklılık göstermektedir. Ancak akıllı saatlerde bu durum böyle

Tablo 7. CNN-LSTM modeli test sonuçları (CNN-LSTM model test results)

CNN-LSTM Modeli						
	BatchSize	TimeStep	Step	nStep	nLenght	Doğruluk
İvme Sensörü (HAR-P ACG)	32	300	20	15	20	0,912
	32	200	10	10	20	0,894
	32	200	20	10	20	0,885
	32	500	20	20	25	0,917
	32	400	20	20	20	0,919
Doğrusal Hızlanma Sensörü (HAR-P ACC)	32	300	20	15	20	0,909
	32	200	10	10	20	0,896
	32	200	20	10	20	0,898
	32	500	20	20	25	0,895
	32	400	20	20	20	0,908
Jiroskop Sensörü (HAR-P Gyro)	32	300	20	15	20	0,871
	32	200	10	10	20	0,856
	32	200	20	10	20	0,827
	32	500	20	20	25	0,876
	32	400	20	20	20	0,886
Manyetik Alan Sensörü (HAR-P Magnet)	32	300	20	15	20	0,861
	32	200	10	10	20	0,856
	32	200	20	10	20	0,825
	32	500	20	20	25	0,843
	32	400	20	20	20	0,871

Tablo 8. CNN-LSTM modeli test sonuçları (CNN-LSTM model test results)

a) Doğrusal Hızlanma Sensörü				b) İvme Sensörü			
	Kesinlik	Duyarlılık	F1-puani		Kesinlik	Duyarlılık	F1-puani
Downstairs	0,93	0,946	0,936	Downstairs	0,886	0,93	0,908
Praying	0,974	0,88	0,924	Praying	0,956	0,908	0,932
Running	0,984	0,984	0,984	Running	0,986	0,982	0,986
Sitting	0,772	0,806	0,788	Sitting	0,698	0,73	0,712
Standing	0,71	0,94	0,806	Standing	0,88	0,932	0,904
Typing	0,87	0,938	0,902	Typing	0,786	0,878	0,826
Upstairs	0,836	0,91	0,872	Upstairs	0,812	0,886	0,846
Walking	0,896	0,866	0,88	Walking	0,892	0,846	0,866
Doğruluk			0,896	Doğruluk			0,894
Ağırlıksız Ortalama	0,874	0,908	0,888	Ağırlıksız Ortalama	0,862	0,886	0,872
Ağırlıklı Ortalama	0,91	0,896	0,902	Ağırlıklı Ortalama	0,898	0,894	0,894
c) Manyetik Alan Sensörü				d) Jiroskop Sensörü			
	Kesinlik	Duyarlılık	F1-puani		Kesinlik	Duyarlılık	F1-puani
Downstairs	0,728	0,778	0,748	Downstairs	0,784	0,908	0,84
Praying	0,93	0,92	0,924	Praying	0,92	0,884	0,902
Running	0,974	0,982	0,982	Running	0,984	0,982	0,98
Sitting	0,688	0,716	0,698	Sitting	0,698	0,702	0,698
Standing	0,832	0,838	0,832	Standing	0,688	0,772	0,722
Typing	0,878	0,754	0,806	Typing	0,868	0,854	0,862
Upstairs	0,708	0,802	0,75	Upstairs	0,82	0,822	0,818
Walking	0,812	0,752	0,776	Walking	0,858	0,8	0,828
Doğruluk			0,856	Doğruluk			0,856
Ağırlıksız Ortalama	0,818	0,818	0,814	Ağırlıksız Ortalama	0,828	0,84	0,832
Ağırlıklı Ortalama	0,864	0,856	0,856	Ağırlıklı Ortalama	0,86	0,856	0,856

değildir. Akıllı saatler, kişinin ya sol bileğine ya da sağ bileğine takılmaktadır. Bu da deney ortamında geliştirilen bir uygulamanın, gerçek ortamda farklılık göstermeden doğru bir şekilde çalışmasını sağlamaktadır. Bu yüzden sensör tabanlı aktivite tanıma yönelik çalışmalar için son zamanlarda akıllı telefon yerine akıllı saat gibi giyilebilir cihazlar tercih edilmektedir.

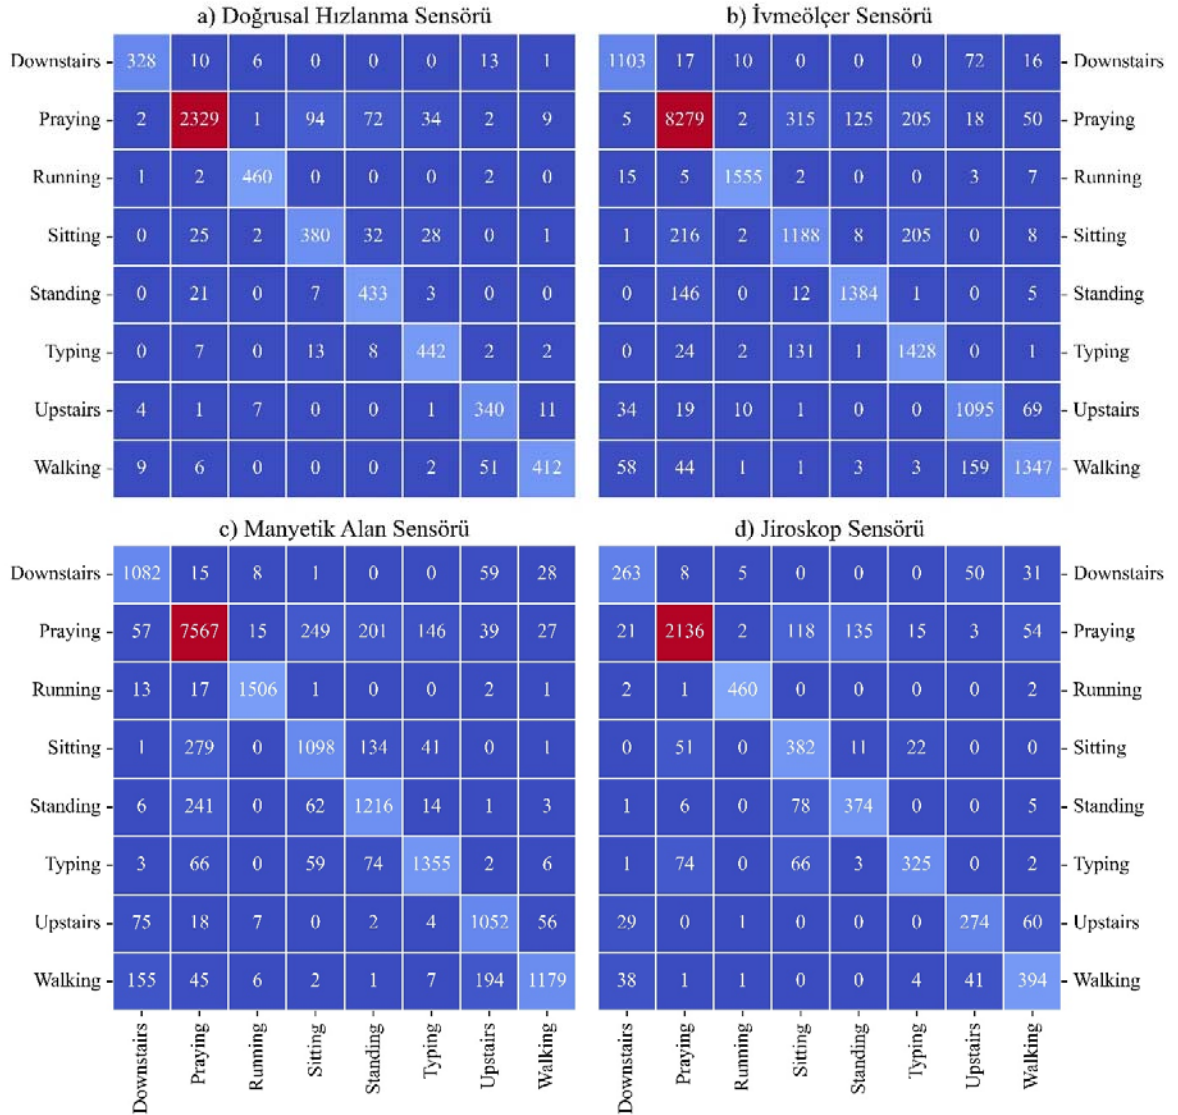
4. Sonuçlar (Conclusions)

İnsanlar günlük yaşantılarının büyük bir bölümünü, internete bağlı bir cihaz karşısında geçirmektedir. Bu süre boyunca kullanıcıların çoğu, internete geçirdiği vakti kestirememektedir. Uzun süre teknolojik

cihazların karşısında hareketsiz (az hareketli) durmak sağlık açısından olumsuz görülmektedir. Ayrıca zaman kavramının yitirilmesinden dolayı namaz kılmak gibi belirli zamanlarda yapılması gereken davranışlar unutulabilmektedir. Özellikle masa başı ve yoğun çalışan kişilerin gün içinde belirli zamanlarda yapmaları gereken davranışları hatırlatmak ve engelli, yaşlı bireylerin unutarak yapmadıkları (yemek yeme, ilaç alma) davranışları hatırlatmak amacıyla insan hareketlerinin sınıflandırılması önemli bir çalışma alanıdır.

Bu çalışma kapsamında, yeni bir karmaşık aktivite türü olan, Müslüman bireylerin günde beş vakit yapmakla mükellef olduğu namaz kıma eyleminin sınıflandırılması amaçlanmıştır. Namaz kıma

CNN-LSTM Modeli Test Sonuçları



Şekil 15. CNN-LSTM Modeli için Karmaşıklık Matrisi (Confusion Matrix for the CNN-LSTM Model)

Tablo 9. Tüm test sonuçları (All test results)

Sensör Model	Doğrusal Hızlanma Sensörü	İvme Sensörü	Manyetik Alan Sensörü	Jiroskop Sensörü
LSTM	0,910	0,898	0,854	0,844
ConvLSTM	0,894	0,910	0,876	0,836
CNN-LSTM	0,896	0,894	0,856	0,856

eylemi belirli bir zaman diliminde yapılması gerekmektedir. İnsanlar, bu namaz vakitlerinin takibi için internetteki belirli kaynakları veya akıllı telefon / tabletlere yüklenen mobil uygulamalar kullanmaktadırlar. Ancak bu kaynakların hiçbiri o kişinin namaz eylemini o vakit diliminde gerçekleştirip gerçekleştirmediğini tespit etmemektedir. Namaz kılma eylemi literatürde yeni bir karmaşık aktivite türü olması; namaz kılma vaktinin takibi ve namazın kılınma durumunu hatırlatacak akıllı dijital bir asistana olan ihtiyaçtan dolayı namaz kılma eyleminin tespit edilmesi önemli bir araştırma konusudur.

Bu çalışmada el bileğine takılan akıllı saat sensör verileri ile insan hareketlerinin sınıflandırmasının yapılabileceği görülmüştür. İvmeölçer sensörü ve varyantı olan doğrusal hızlanma sensörü kullanılarak yapılan sınıflandırmanın, jiroskop ve manyetik alan sensörlerine göre nispeten daha yüksek başarı oranları verdiği sonucuna ulaşılmıştır. Tablo 8’de verilen sonuçlar, üç modelin ortak pencere boyutundaki test sonuçlarını göstermektedir. Her modelin bireysel testlerinde bu tabloda yer almayan daha yüksek değerlere ulaşılmıştır. Her model için hiper parametre optimizasyonları yapılarak daha da yüksek doğruluk oranlarına ulaşılabilmektedir. Bu çalışmada yeni oluşturulup paylaşılma açılan HAR-P veri kümesinde kullanılan dört sensör çeşidinin, donanımsal farklılıklarından dolayı verdikleri veri sayısı farklı olmuştur. Bu nedenle bu çalışma kapsamında sensör çeşitlerinin tekil etkileri karşılaştırılmıştır. Bundan sonraki çalışmalarda, HAR-P veri kümesindeki dört sensörün veri sayıları eşitlenmeye çalışılacaktır. Böylece HAR-P veri kümesindeki dört sensör verisi tek bir dosyada toplanarak, çoklu sensörün sınıflandırma başarısı karşılaştırılacaktır. Ayrıca veri kümesinin %45’lik çoğunluğunu oluşturan “Praying” aktivitesi kendi içerisinde, namazın bölümlerini gösterecek şekilde bölümlenerek, namaz kılma üzerinde farklı çalışmalar yapılacaktır. Bu çalışmalara; kılınan namazın rekât sayısının belirlenmesi, namaz hareketlerini doğru yapıyla durumunun tespiti, bulunan konuma göre namazın vakti çıkmadan kılınmaması namazın hatırlatılmasının yapılması, kılınmayan namazların (kaza yapılması gereken) belirlenmesi gibi örnekler verilebilir.

Teşekkür (Acknowledgement)

Bu çalışma, Konya Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 231113013 proje numarasıyla desteklenmiştir. Çalışmamızda veri toplama aşamasında katkısı olan gönüllülere teşekkür ederiz.

Kaynaklar (References)

- Chen, K., Zhang, D., Yao, L., Guo, B., Yu, Z., Liu, Y., Deep learning for sensor-based human activity recognition: Overview, challenges, and opportunities, *ACM Computing Surveys*, 54 (4), 1-40, 2021.
- Pareek, P., Thakkar, A., A survey on video-based human action recognition: recent updates, datasets, challenges, and applications, *Artificial Intelligence Review*, 54, 2259-2322, 2021.
- Iskanderov, J., Güvensan, M.A., Akıllı telefon ve giyilebilir cihazlarla aktivite tanıma: Klasik yaklaşımlar, yeni çözümler, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 25 (2), 223-239, 2019.
- Kwapisz, J.R., Weiss, G.M., Moore, S.A., Activity recognition using cell phone accelerometers, *ACM SigKDD Explorations Newsletter*, 12 (2), 74-82, 2011.
- Balli, S., Sağbaş, E.A., Peker, M., Human activity recognition from smart watch sensor data using a hybrid of principal component analysis and random forest algorithm, *Measurement Control*, 52 (1-2), 37-45, 2019.
- Siirtola, P., Röning, J., Recognizing human activities user-independently on smartphones based on accelerometer data, *IJIMAI*, 1 (5), 38-45, 2012.
- Garain, A., Dawn, R., Singh, S., Chowdhury, C., Differentially private human activity recognition for smartphone users, *Multimedia Tools Applications*, 81 (28), 40827-40848, 2022.
- Sousa Lima, W., Souto, E., El-Khatib, K., Jalali, R., Gama, J., Human activity recognition using inertial sensors in a smartphone: An overview, *Sensors*, 19 (14), 3213, 2019.
- Mekruksavanich, S., Jitpattanukul, A., Lstm networks using smartphone data for sensor-based human activity recognition in smart homes, *Sensors*, 21 (5), 1636, 2021.
- Javed, A.R., Faheem, R., Asim, M., Baker, T., Beg, M.O., A smartphone sensors-based personalized human activity recognition system for sustainable smart cities, *Sustainable Cities Society*, 71, 102970, 2021.
- Mekruksavanich, S., Jitpattanukul, A., Smartwatch-based human activity recognition using hybrid lstm network, in *2020 IEEE SENSORS*, 2020.
- Boyer, P., Burns, D., Whyne, C., Out-of-distribution detection of human activity recognition with smartwatch inertial sensors, *Sensors*, 21 (5), 1669, 2021.
- Albert, M.V., Toledo, S., Shapiro, M., Kording, K., Using mobile phones for activity recognition in Parkinson’s patients, *Frontiers in neurology*, 3, 158, 2012.
- Lee, J., Kim, J., Energy-efficient real-time human activity recognition on smart mobile devices, *Mobile Information Systems*, 2016.
- Anguita, D., Ghio, A., Oneto, L., Parra, X., Reyes-Ortiz, J.L., Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine, *Ambient Assisted Living and Home Care: 4th International Workshop, IWAAL 2012, Vitoria-Gasteiz, Spain, 216-223, 3-5 Aralık, 2012*.
- Sztyler, T., Stuckenschmidt, H., Petrich, W.J.P., Position-aware activity recognition with wearable devices, *Pervasive Mobile Computing*, 38, 281-295, 2017.
- Metin İ.A., Karasulu B., A novel dataset of human daily activities: Its benchmarking results for classification performance via using deep learning techniques, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2), 759-777, 2021.
- Borazio, M., Van Laerhoven, K., Using time use with mobile sensor data: a road to practical mobile activity recognition?, *Proceedings of the 12th International Conference on Mobile and Ubiquitous Multimedia*, 1-10, 2013.
- Lee, Y.-S., Cho, S.-B., Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer, *Hybrid Artificial Intelligent Systems: 6th International Conference, HAIS 2011, Wrocław, Poland, 23-25 Mayıs, 2011*.
- Riboni, D., Bettini, C., COSAR: hybrid reasoning for context-aware activity recognition, *Personal Ubiquitous Computing*, 15 (3), 271-289, 2011.
- Zhao, Z., Chen, Y., Liu, J., Shen, Z., Liu, M., Cross-people mobile-phone based activity recognition, *Twenty-second international joint conference on artificial intelligence*, 2011.
- Peng, J.-X., Ferguson, S., Rafferty, K., Kelly, P.D., An efficient feature selection method for mobile devices with application to activity recognition, *Neurocomputing*, 74 (17), 3543-3552, 2011.
- Hsu, H.-H., Chu, C.-T., Zhou, Y., Cheng, Z., Two-phase activity recognition with smartphone sensors, *18th International Conference on Network-Based Information Systems, IEEE*, 2015.
- Dernbach, S., Das, B., Krishnan, N.C., Thomas, B.L., Cook, D.J., Simple and complex activity recognition through smart phones, in *2012 eighth international conference on intelligent environments, IEEE*, 2012.
- Ustev, Y.E., Durmaz Incel, O., Ersoy, C., User, device and orientation independent human activity recognition on mobile phones: Challenges and a proposal, *Proceedings of the 2013 ACM conference on Pervasive and ubiquitous computing adjunct publication*, 2013.
- Vo, Q.V., Hoang, M.T., Choi, D., Personalization in mobile activity recognition system using K-medoids clustering algorithm, *International Journal of Distributed Sensor Networks*, 9 (7), 315841, 2013.
- Chung, S., Lim, J., Noh, K.J., Kim, G., Jeong, H., Sensor data acquisition and multimodal sensor fusion for human activity recognition using deep learning, *Sensors*, 19 (7), 1716, 2019.
- Abdallah, Z.S., Gaber, M.M., Srinivasan, B., Krishnaswamy, S., Adaptive mobile activity recognition system with evolving data streams, *Neurocomputing*, 150, 304-317, 2015.
- Concepción, M.Á.Á., Morillo, L.M.S., García, J.A.Á., González-Abril, L., Mobile activity recognition and fall detection system for elderly people using Ameva algorithm, *Pervasive Mobile Computing*, 34, 3-13, 2017.
- Acharjee, D., Mukherjee, A., Mandal, J., Mukherjee, N., Activity recognition system using inbuilt sensors of smart mobile phone and

- minimizing feature vectors, *Microsystem Technologies*, 22 (11), 2715-2722, 2016.
31. Henpraserttae, A., Thiemjarus, S., Marukatat, S., Accurate activity recognition using a mobile phone regardless of device orientation and location, *International Conference on Body Sensor Networks*, IEEE, 2011.
 32. Yan, Z., Subbaraju, V., Chakraborty, D., Misra, A., Aberer, K., Energy-efficient continuous activity recognition on mobile phones: An activity-adaptive approach, *16th international symposium on wearable computers*, IEEE, 2012.
 33. Martín, H., Bernardos, A.M., Iglesias, J., Casar, J.R., Activity logging using lightweight classification techniques in mobile devices, *Personal ubiquitous computing*, 17 (4), 675-695, 2013.
 34. Kuncan F., Kaya Y., Kuncan M., New approaches based on local binary patterns for gender identification from sensor signals, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 2173-2186, 2019.
 35. Yüksel, A.S., Şenel, F.A., Çankaya, İ.A., Yazma davranışlarının mobil cihaz sensörleri kullanılarak sınıflandırılması, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9 (1), 133-142, 2018.
 36. Huynh, Q.T., Nguyen, U.D., Irazabal, L.B., Ghassemian, N., Tran, B.Q., Optimization of an accelerometer and gyroscope-based fall detection algorithm, *Journal of Sensors*, 2015.
 37. Sağbaş, E.A., Ballı, S., Akıllı telefon algılayıcıları ve makine öğrenmesi kullanılarak ulaşım türü tespiti, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22 (5), 376-383, 2016.
 38. Lockhart, J.W., Weiss, G.M., Xue, J.C., Gallagher, S.T., Grosner, A.B., Pulickal, T.T., Design considerations for the WISDM smart phone-based sensor mining architecture, *Proceedings of the Fifth International Workshop on Knowledge Discovery from Sensor Data*, 2011.
 39. Zappi, P., Lombriser, C., Stiefmeier, T., Farella, E., Roggen, D., Benini, L., Tröster, G., Activity recognition from on-body sensors: accuracy-power trade-off by dynamic sensor selection, *Wireless Sensor Networks: 5th European Conference, EWSN 2008, Bologna - Italy*, 30 Ocak-1 Şubat, 2008.
 40. Chavarriaga, R., Sagha, H., Calatroni, A., Digumarti, S.T., Tröster, G., Millán, J.d.R., Roggen, D., The Opportunity challenge: A benchmark database for on-body sensor-based activity recognition, *Pattern Recognition Letters*, 34 (15), 2033-2042, 2013.
 41. Repcik, T. SensorBox: Android app to measure sensors. <https://github.com/Foxpace/SensorBox>. Yayın tarihi Eylül 21, 2021. Erişim tarihi Nisan 11, 2021.
 42. Google. Sensors Overview Android Developers. https://developer.android.com/guide/topics/sensors/sensors_overview. Erişim tarihi Mayıs 11, 2022.
 43. Van Der Maaten, L., Accelerating t-SNE using tree-based algorithms, *The journal of machine learning research*, 15 (1), 3221-3245, 2014.
 44. Community, s. sklearn.model_selection.StratifiedKFold scikit-learn 1.3.0 documentation. https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.StratifiedKFold.html. Erişim tarihi Temmuz 3, 2023.
 45. Hochreiter, S., Schmidhuber, J., Long short-term memory, *Neural computation*, 9 (8), 1735-1780, 1997.
 46. Shi, X., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., Woo, W. C., Convolutional LSTM network: A machine learning approach for precipitation nowcasting, *Advances in neural information processing systems*, 28, 2015.

