



Makine Öğrenmesi Yöntemleri Kullanılarak İnsan Aktivitesinin Sınıflandırılması

Yazılım Mühendisliği Ana Bilim Dalı

Dönem Projesi

Muhammed Onur Öztürk

ORCID 0009-0008-3418-5150

Proje Danışmanı: Prof. Dr. Doğan Aydın

Ocak 2024

Makine Öğrenmesi Yöntemleri Kullanılarak İnsan Aktivitesinin Sınıflandırılması

Öz

Bu çalışma, fiziksel aktivitelerin objektif bir şekilde değerlendirilmesi amacıyla ivmeölçerler, jiroskoplar ve atalet ölçüm üniteleri (IMU) gibi sensörlerin kullanılmasını ele almaktadır. Bu sensörler, insan aktivitelerinin sınıflandırılması için kullanılarak, özellikle yürüyüş özelliklerinin değerlendirilmesine olanak tanımaktadır. IMU'lar, ivmeölçer ve jiroskop gibi sensörleri birleştirerek daha güvenilir veri sağlamaktadır.

Derin öğrenme modelleri, bu sensör verilerini kullanarak oturma, yürüme, merdiven çıkma/iniş, düşme gibi aktiviteleri sınıflandırma yeteneği göstermektedir. Ancak, durağan verilerin ayırt edilmesi zorluğuyla karşılaşmaktadır. Bu çalışma, bu zorluğu aşmak için istatistiksel parametreler, konvolüsyonlar ve frekans alanı özellikleri gibi çeşitli özellik temsillerini birleştiren bir yaklaşımı ele almaktadır.

Çalışma, giyilebilir IMU sensörlerinin kullanıldığı İnsan Aktivitesi Tanımlama (HAR) alanındaki literatürü incelemekte ve yaşlı bakımı, Ortam Destekli Yaşam (AAL) ve sağlıklı yaşam gibi uygulama alanlarını tartışmaktadır. Ayrıca, düşme tespiti, parkinson hastalığı teşhisi gibi örnek uygulamalara odaklanan önceki çalışmalardan örnekler sunmaktadır.

Çalışmanın metodolojisi, IMU sensör verilerinin kullanıldığı bir veri setini içermektedir. Derin öğrenme yöntemleri, özellikle LSTM (Uzun Kısa Süreli Bellek) modeli kullanılarak çeşitli senaryolarda eğitilmiş ve değerlendirilmiştir. Sonuçlar, gizli katmandaki nöron sayısı, epoch sayısı ve batch_size gibi parametrelerin modelin doğruluk oranını etkilediğini göstermiştir.

Çalışmanın bulguları, derin öğrenme modelleri kullanarak giyilebilir sensör verilerinden elde edilen aktivite tahmininin önemli bir potansiyele sahip olduğunu ve bu yaklaşımın sağlık sektörü ve tele-rehabilitasyon gibi alanlarda uygulanabilir olduğunu vurgulamaktadır.

Anahtar Sözcükler: İnertial Ölçüm Birimi (İÖB), İnsan Aktivitesi Tanıma (İAT), İvmeölçer, Jiroskop, Derin Öğrenme Modelleri, Uzun Kısa Süreli Bellek (LSTM), Fiziksel Aktivite Değerlendirmesi, Sensör Birleştirme

Classification of Human Activities Using Machine Learning Methods

Abstract

This study addresses the use of sensors such as accelerometers, gyroscopes, and Inertial Measurement Units (IMUs) for the objective evaluation of physical activities. These sensors are employed to classify human activities, particularly enabling the assessment of walking characteristics. IMUs, by combining sensors like accelerometers and gyroscopes, provide more reliable data.

Deep learning models demonstrate the ability to classify activities such as sitting, walking, stair climbing/descending, and falling using data from these sensors. However, distinguishing static activities poses a challenge. This study tackles this difficulty by adopting an approach that combines various feature representations, including statistical parameters, convolutions, and frequency domain features.

The research reviews the literature in the field of Human Activity Recognition (HAR) using wearable IMU sensors, discussing application areas such as elderly care, Ambient Assisted Living (AAL), and healthy living. It also provides examples from previous studies focusing on applications like fall detection and Parkinson's disease diagnosis.

The methodology of the study includes a dataset utilizing IMU sensor data. Deep learning methods, specifically the Long Short-Term Memory (LSTM) model, are trained and evaluated in various scenarios. Results indicate that parameters such as the number of neurons in the hidden layer, epochs, and batch size significantly influence the accuracy of the model.

The findings of the study emphasize the significant potential of activity prediction derived from wearable sensor data using deep learning models. It highlights the applicability of this approach in sectors like healthcare and tele-rehabilitation.

Keywords: Inertial Measurement Unit (IMU), Human Activity Recognition (HAR), Accelerometer, Gyroscope, Deep Learning Models, Long Short-Term Memory (LSTM), Physical Activity Assessment, Sensor Fusion

İçindekiler

Öz	i
Abstract	iii
Şekiller Tablosu	vi
1. GİRİŞ	1
2. LİTARATÜR TARAMA	3
A. Yapay Ortam Desteli Yaşam - AAL	3
B. Sağlıklı Yaşam – HAR	4
3. ARAŞTIRMANIN YÖNTEMİ	5
A. Veri Seti	5
B. Yöntem	7
C. Bulgular	9
D. Sonuçlar	13
Kaynakça	14

Şekiller Tablosu

Şekil 1: Eğitim Süreci Grafiği.....	9
Şekil 2: Hata Matriksi	10
Şekil 3: Eğitim Süreci Grafiği 2.....	10
Şekil 4: Hata Matriksi 2	11
Şekil 5: Eğitim Süreci Grafiği 3.....	11
Şekil 6: Hata Matriksi 3	12
Şekil 7: Eğitim Süreci Grafiği 4.....	12
Şekil 8: Hata Matriksi 4	13

1. GİRİŞ

Fiziksel aktivite (FA) geleneksel olarak anketlerle değerlendirilebilmektedir, ancak bu nitel yaklaşımdır ve limitasyonlar içermektedir. Bu nedenle daha objektif değerlendirmelerin kullanılması gerekmektedir [1]. İvmeölçerler ve jiroskoplar ve atalet ölçüm üniteleri (Inertial Measurement Units-IMU) günümüzde fiziksel durumun değerlendirilmesi için en yaygın kullanılan çözümlerdir. Bu küçük ve ucuz sensörler, yürüyüş özelliklerinin değerlendirmesini mümkün kılmaktadır [2,3]. Bu sensörler tamamlayıcı bilgi sağlamak için ayrı ayrı ya da birlikte kullanılabilirler.

İvmeölçerler, belirli bir noktadan bir veya daha fazla yöndeki doğrusal ivmeyi ölçen sensörlerdir. Bu sensörler, vücudun statik konumunu tahmin etmek ve ayrıca özellikle açık ortamlarda belirli hareketleri tespit etmek ve incelemek için kullanılabilir [4]. Jiroskoplar, belirli bir noktadan bir veya daha fazla yöndeki açısal hızları ölçer [5]. Ayrıca yürüyüşünün stabilitesini değerlendirmek için vücudun farklı bölümleri arasındaki eklem hareket açıklıklarının hesaplanması için kullanılabilir [6]. Son olarak, IMU'lar, bir ivmeölçer, jiroskop ve bazen manyetometre kombinasyonunu kullanarak bir cismin özgül kuvvetini, açısal hızını ve bazen vücudun oryantasyonunu ölçen ve raporlayan elektronik bir cihazdır. IMU'lar mutlak manyetik alanı ölçen manyetometre sayesinde tüm göreceli nicelikler (ivmeler ve açısal hızlar gibi) birçok durumda uygun olabilecek bir mutlak analiz çerçevesine yansıtılabilir. Jiroskop ve ivmeölçer tek başlarına güvenli ve stabil veriler sağlayamayabilirler. Bu yüzden birbirlerini referans alarak iki sensör birleştirilir ve hız, pozisyon gibi bilgiler tek bir birimden yani IMU'dan alınır. Ayrıca, tüm bu sensörler 1D olabilir (dolayısıyla değerlendirmeleri yalnızca bir yönde ölçerler), ancak son çalışmaların çoğu, ivmelerin, açısal hızların ve manyetik alanların kaydedildiği 3D sensörlere dayanmaktadır [6].

Mikroelektronikteki teknolojik gelişmeler, IMU sensörlerini barındırma ve kablosuz iletim yeteneği dahil olmak üzere temel olanaklara sahip cihazların üretiminin gelişmesi sağlamaktadır. Bu teknolojik gelişmenin merkezinde, fizyolojik tıbbi teşhis [7], lokasyon belirleme ve navigasyon [8], mobil ve kablosuz bağlam odaklı karar destek sistemleri [9] ve güvenlik-izleme gibi talepler yatmaktadır. IMU sensörlerinin üretebildiği veriler, ürün sınırlamalarına bağlı olarak jiroskop, ivmeölçer ve manyetometreden küresel konumlandırma sistemi (GPS) bilgilerine kadar çeşitlilik

göstermektedir. Bu IMU verilerinin elde edilmesi veriye ve bilgiye dayalı öğrenme modelleri, veri ayırt edilebilirliği ile doğrudan ilişkilidir.

Derin öğrenme modelleri, veriye dayalı öğrenme modelleridir. Çalışmalar [10,11], derin öğrenme modellerinin oturma, yürüme, merdiven inme – çıkma ve düşme gibi insan aktivitelerini öğrenebildiğini ve ayırt edebildiğini göstermiştir. Bununla birlikte nispeten durağan veriler üreten belirli faaliyetlerin, aralarında ayırım yapmanın zor olduğunu da bildirmektedir [11]. Oturma, ayakta durma ve uzanma (Sağ, sola, sırt üstü ve yüz üstü) gibi hareketler örnek olarak verilebilir [12]. Farklı aktivitelerin nispeten durağan verilerini ayırt etmedeki zorluk, bu hareketlerin özellik temsillerinin benzerliğinden kaynaklanmaktadır. Örneğin; bu tür veriler sinyaller olarak düşünüldüğünde, frekans alanına dönüşümler nispeten benzer spektral bilgileri gösterebilmektedir. Bu nedenle, sınıflandırma amaçları için uygun özellik belirleme mekanizmaları çok önemlidir.

İstatistiksel parametreler zaman serisi verileri için popülerken, konvolüsyonlar görüntü işleme çalışmalarında popülerdir. Bununla birlikte bazı çalışmalar, veri gösterimi için istatistiksel özellikler ve frekans alanı özelliklerinin bir kombinasyonunu kullanmayı tercih etmiştir [10]. Tercih edilen kombinasyonlar her zaman özellik vektörünün kalitesini iyileştirmeye yönelik bir seçimdir. Bu nedenle, bir özellik temsili yaklaşımındaki kilit nokta, her bir veri sınıfının içsel karakteristiğini temsil edilmesi gereken verinin kalitesindedir. Verilerin boyut indirgemesi için kullanılan geleneksel yaklaşımlar, temel bileşen analizini (Principal Component Analysis - PCA) [13] ve tanımlanmış çekirdekleri kullanan evrişim yaklaşımlarını (Convolution Approaches) içermektedir [10].

Belirli bir veri sınıfı için bir özellik temsili, ancak aynı sınıfın ham veri varyantlarının tamamı veya çok büyük bir yüzdesini temsil ediliyorsa, kalite açısından kapsamlı olarak kabul edilebilmektedir.

2. LİTARATÜR TARAMA

Giyilebilir IMU sensörlerini kullanılarak elde edilen İnsan Aktivitesi Tanımlamaları (Human Activity Recognition – HAR) birçok kullanım alanına sahiptir. Bu nedenle HAR çalışmaları günümüzde oldukça ilgi görmektedir. Halihazırda, giyilebilir sensörlere dayalı HAR'ı kullanmayı amaçlayan alana özgü çeşitli çalışmalar yapılmıştır. Literatür özetinde yaşlı bakımı, insan davranışlarını anlama için Ortam Destekli Yaşam (Ambient Assisted Living-AAL) ve sağlıklı yaşam için HAR'ın incelemesi yapılmıştır.

A. Yapay Ortam Destekli Yaşam - AAL

Ortam destekli yaşamın temeli kişilerin fiziksel zayıflıkları ve insan engelleri ne olursa olsun bağımsız olarak yaşayabilmeleridir. Yardımcı teknolojiler bu vizyonun arkasındaki temel itici güçlerdir. Yaşlı kişilerde düşme tespiti AAL çalışmalarında en popüler uygulama olarak görülmektedir [14]. Parkinson gibi hastalıkların neden olduğu titreme, hızlı teşhis ve tedavilere yardımcı olmak için çalışmalarda nicel olarak değerlendirilmektedir.

Mao ve arkadaşları [14], Kalman çözümlerini kullanarak kullanıcıların vücudunun oryantasyonunu temsil etmek için giyilebilir bir mikro-elektro-mekanik sistem (MEMS) sensöründen çıkarılan hızlanma ve Euler açısı verilerine dayalı bir düşme algılama yöntemi önermiştir. Sensörler deneklerin omuzlarına, bellerine ve ayaklarına yerleştirilmiş ve doğru düşme tespiti için bir hızlanma eşiği belirlenmiştir. Yani hızlanma eşiği, sınıflandırma için anahtar özellik olarak hareket etmektedir. Ancak, eşik yaklaşımında elde edilen doğruluklara rağmen, adapte edilebilir bir eşik yaklaşımı düşme tespiti için daha güvenilir sonuçlar sunacaktır. Bunun nedeni, insanların, özellikle yaşlandıkça doğal olarak farklı yapılara sahip olmalarıdır.

Pierleoni ve arkadaşları [15] giyilebilir bir cihazda uygulanan bir düşme algılama algoritması önermiştir. Kullanılan sistem bir IMU sensöründen gelen üç eksenli ivmeölçer, jiroskop ve manyetometre verilerinin bir birleşiminin kullanılmasıdır. Deneğin belirlenen yönünden elde edilen sapmaların karekök ortalaması (RMS) elde edilerek düşme olup olmadığını belirlenmiştir. En küçük kareler metodu kullanılarak Parkinson hastalarında bir değerlendirme yapılmıştır. Titreme ölçümü, IMU verilerinden elde edilen bir zaman-frekans sinyali özelliklerine dayandırılmıştır.

B. Sağlıklı Yaşam – HAR

```
def load_file(filepath):  
  
    dataframe = read_csv(filepath, header=None,  
                        delim_whitespace=True)  
  
    return dataframe.values
```

Sağlıklı ve zinde kalınabilmesi için beslenmenin yanı sıra egzersize de ihtiyacı vardır. Fitness odaklı uygulamalar, insan aktivitelerini otomatik olarak tanımlayarak, bunları günlüğe kaydeder ve vücut uygunluk değerlendirmeleri için istatistiksel analizler yapabilirler [16]. Bu amaçla akıllı saatler veya telefonlar gibi giyilebilir cihazlar, veri üretmek için atalet sensörleri ve geri bildirim amacıyla kullanıcı analizi yazılım uygulamaları ile donatılmıştır [17]. Sporla ilgili aktiviteler arasında yüzme, koşu, yürüyüş, atlama, şınav, koşma, futbol oynama, paten kayma yer almaktadır. Literatürde yer alan bazı çalışmalarda yürüme, ayakta durma, oturma, uzanma, üst kata çıkma, bisiklete binme, koşma gibi aktivitelerin derin evrışimsel sinir ağı (CNN) öğrenme metodolojisine dayalı olarak belirlenebildiği belirtilmiştir (10,11) Evrışim teorisine dayalı olarak, her iki çalışmada da kullanılan öznelikler, [11]'deki orijinal veri setine ve [10]'deki spektrograma tanımlanmış filtrelerin uygulanmasının bir sonucu olarak elde edilmiştir. Bir diğer çalışmada yüzme stili, kulaç sayacı, vücut dengesi ve rotasyonu belirleme yeteneğine sahip SwimMaster adlı bir veri analiz aracı geliştirilmiştir. Veri toplama amacıyla yüzücülerin üst koluna, alt sırtına ve sağ bileğine atalet sensörleri yerleştirilmiştir. Çalışma parametrelerinin değerlendirilmesi, ayırt edici özellikler olarak sapma ve eğim değerlerinin analizine dayandırılmıştır.

İnsan hareketlerinin belirlenmeye çalışıldığı bir diğer ad modeli ise Uzun Kısa Süreli Bellektir (LSTM). LSTM ağ modelleri, uzun giriş verisi dizileri üzerinden öğrenebilen ve hatırlayabilen bir tür tekrarlayan sinir ağıdır. 200 ila 400 zaman adımına kadar uzun veri dizilerinden oluşan verilerle kullanım için tasarlanmıştır. Model, ivmeölçer ve jiroskop verilerinin her bir eksenini gibi birden çok paralel giriş verisi dizisini

destekleyebilmektedir. Dizi sınıflandırması için LSTM'leri kullanmanın yararı, doğrudan ham zaman serisi verilerinden öğrenebilmeleri ve dolayısıyla girdi özelliklerini manuel olarak tasarlamak için alan uzmanlığı gerektirmemeleridir.

3. ARAŞTIRMANIN YÖNTEMİ

A. Veri Seti

İlk adım, ham veri setinin yüklenmesidir. Ham verilerde üç ana sinyal türü içermektedir: total ivme, vücut ivmesi ve vücut jiroskopu. Her birinin üç veri eksenine vardır. Bu, her zaman adımı için toplam dokuz değişken olduğu anlamına gelir. Her bir veri dizisi, 2,65 saniyelik veri veya 128 zaman adımından oluşan örtüşen pencerelere bölünmüştür. Bu, bir veri satırının 128×9 yani 1.152 öğeye sahip olduğu anlamına gelir.

Aşağıdaki `load_file()` fonksiyonu, veri kümesini yükler ve yüklenen verileri bir NumPy dizisi olarak döndürür.

```
def load_group(filenamees, prefix=' '):
    loaded = list()
    for name in filenamees:
        data = load_file(prefix + name)
        loaded.append(data)
    loaded = dstack(loaded)
    return loaded
```

Ardından, belirli bir grup (eğitim veya test) için tüm verileri, dizinin boyutlarının [örnekler, zaman adımları, özellikler] olduğu tek bir üç boyutlu NumPy dizisine

yükleyebiliriz. Örnek sayısı, herhangi bir ham sinyal veri dosyasındaki satır sayısıdır. Aşağıdaki load_group() fonksiyonu bu 3 Boyutlu (3B) dizinin oluşmasını sağlar. dstack() NumPy fonksiyonu ise, yüklenen 3B dizilerin her birini, değişkenlerin üçüncü boyutta (özellikler) ayrıldığı tek bir 3B dizide birleştirmemize olanak tanır.

Eğitim veya test gibi belirli gruplar için tüm giriş sinyali verilerini yüklemek amacıyla kullanabiliriz. Aşağıdaki load_dataset_group() fonksiyonu farklı kişilerden elde edilen verileri eğitim ve test başlıkları gözetilerek birleştirilmesini sağlayacaktır.

```
def load_dataset_group(group, prefix=' '):  
    filepath = prefix + group + '/Inertial Signals/'  
    filenames = list()  
    filenames += ['total_acc_x_'+group+'.txt', 'total_acc_y_'+group+'.  
txt','total_acc_z_'+group+'.txt']  
    filenames += ['body_acc_x_'+group+'.txt',  
'body_acc_y_'+group+'.txt',  
'body_acc_z_'+group+'.txt']  
    filenames += ['body_gyro_x_'+group+'.txt', 'body_gyro_y_'+group+'.txt',  
'body_gyro_z_'+group+'.txt']  
    X = load_group(filenames, filepath)  
    y = load_file(prefix + group + '/y_'+group+'.txt')  
    return X, y
```

Bir sinir ağında çok sınıflı sınıflandırma modeli oluşturmak için verilerin kategorilendirilmesi gerekmektedir. Bunu to_categorical() Keras fonksiyonunu kullanarak yapabiliriz. Aşağıdaki kodlar çalıştırılarak X ve y öğelerini, tanımlanan modelleri eğitmek ve değerlendirmek için hazır hale getirir.

```
trainX, trainy = load_dataset_group('train', prefix + 'HARDataset/')
print(trainX.shape, trainy.shape)
testX, testy = load_dataset_group('test', prefix
+ 'HARDataset/')
print(testX.shape, testy.shape)
trainy = trainy - 1
testy = testy - 1
trainy = to_categorical(trainy)
testy = to_categorical(testy)
print(trainX.shape, trainy.shape, testX.shape, testy.shape)
```

B. Yöntem

Derin öğrenme yöntemi olarak Keras kütüphanesi kullanılarak LSTM modeli oluşturuldu. Bu model için üç boyutlu bir girdi verisi gerekmektedir. İnsan hareketlerinin belirlenmesi için kullanılacak olan veriler üç boyutlu [örnekler, zaman adımları, özellikler] olarak ayarlanmıştır. Bu çalışmada bir örnek zaman serisi verilerinin bir penceresidir ve her pencere 128 zaman adımına sahiptir. Bir zaman adımı dokuz değişkene veya özelliğe sahiptir. Bu çalışmada 6 farklı hareketin (yürüme, merdiven inme, merdiven çıkma, oturma, ayakta durma ve yatma) belirlenebilmesi çalışılmış ve bu yönde veriler toplanmıştır. Modelin çıktısı, altı aktivite türünün her birine ait belirli bir pencerenin olasılığını içeren altı ögeli bir vektör olacaktır. Model oluşturulurken girdi ve çıktı boyutları gereklidir. Bunlar eğitim veri kümesinden aşağıdaki kod yardımıyla elde edilebilir.

Basit olması için Sequential Keras modeli kullanılmıştır. Model tek bir LSTM gizli katmanına sahip olacaktır. Aşırı öğrenmeyi önlemek için bir Dropout katmanı kullanılmıştır. Son olarak, bir çıktı katmanını kullanılmadan önce, LSTM gizli katmanı tarafından çıkarılan özellikleri yorumlamak için bir tam bağlantılı katman kullanılmıştır. Ağı optimize etmek için Adam versiyonu ve çok sınıflı bir sınıflandırma problemi olduğu için *categorical cross-entropy loss* fonksiyonu kullanılacaktır.

```
model = Sequential()
model.add(LSTM(100, input_shape=(n_timesteps,n_features)))
model.add(Dropout(0.5))
model.add(Dense(100, activation='relu'))
model.add(Dense(n_outputs, activation='softmax'))
model.compile(loss='categorical_crossentropy', optimizer='adam',
metrics=['accuracy'])
```

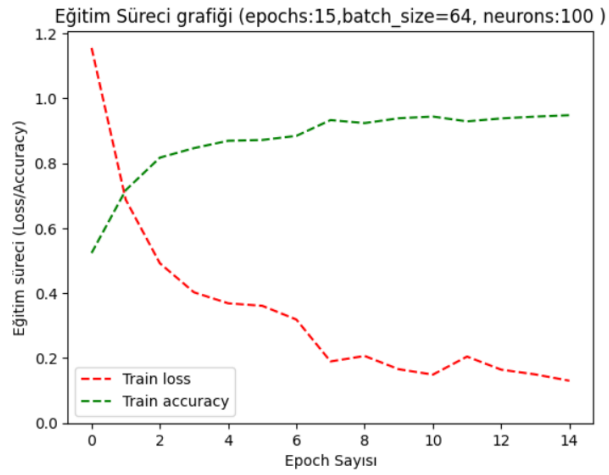
Yukarıda oluşturulan örnek model farklı epoch, batch_size, gizli ve tam bağlantılı katmanın nöron sayısı verileri kullanılarak eğitilecek ve en yüksek doğruluk oranı veren model belirlenecektir. Modelin eğitimi ve doğruluğu değerlendirilmesi aşağıdaki kodlar kullanılarak yapılacaktır.

```
model.fit(trainX, trainy, epochs=epochs,  
batch_size=batch_size, verbose=verbose)
```


```
accuracy = model.evaluate(testX, testy,  
batch_size=batch_size, verbose=0)
```

C. Bulgular

Çalışmada 4 farklı senaryo oluşturulmuştur. İlk senaryoda; gizli katmandaki nöron sayısı 100, epoch sayısı: 15 ve batch_size değeri: 64'tür. Loss değeri 0.213, doğruluk oranı ise 0.920 olmuştur. 1. Senaryonun loss fonksiyonu/doğruluk grafiği ve hata matrisi aşağıdaki gibidir.



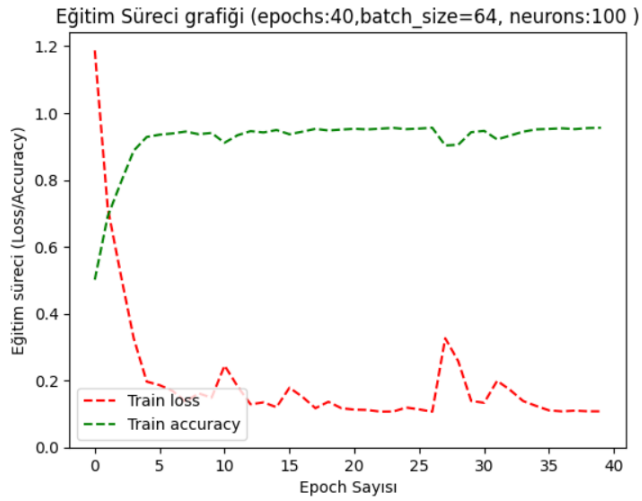
Şekil 1: Eğitim Süreci Grafiği




Aktiviteler: 1-Yürüme, 2-Merdiven Çıkma, 3-Merdiven İnme, 4-Oturma, 5-Ayakta Durma, 6-Yatma

Şekil 2: Hata Matriksi

İkinci senaryoda sadece epoch sayısı arttırılmıştır; gizli katmandaki nöron sayısı 100, epoch sayısı: 40 ve batch_size değeri: 64'tür. Loss değeri 0.340, doğruluk oranı ise 0.910 olmuştur. 2. Seneryonun loss fonksiyonu/doğruluk grafiği ve hata matriksi aşağıdaki gibidir.




Şekil 3: Eğitim Süreci Grafiği 2




Aktiviteler: 1-Yürüme, 2-Merdiven Çıkma, 3-Merdiven İnme, 4-Oturma, 5-Ayakta Durma, 6-Yatma

Şekil 4: Hata Matrisi 2

Üçüncü senaryoda sadece batch-size arttırılmıştır; gizli katmandaki nöron sayısı 100, epoch sayısı: 15 ve batch_size değeri: 128'dir. Loss değeri 0.381, doğruluk oranı ise 0.901 olmuştur. 3. Seneryonun loss fonksiyonu/doğruluk grafiği ve hata matrisi aşağıdaki gibidir.



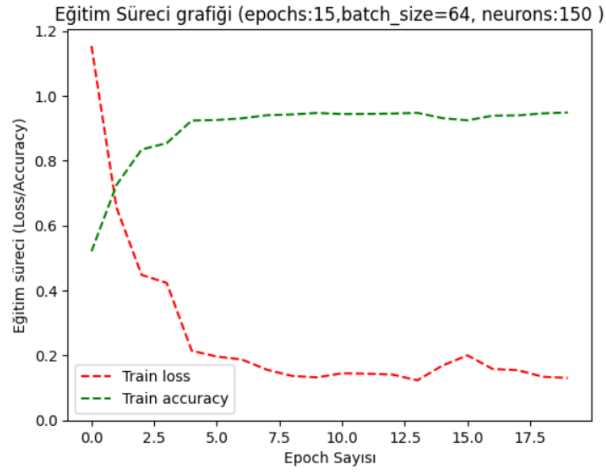
Şekil 5: Eğitim Süreci Grafiği 3



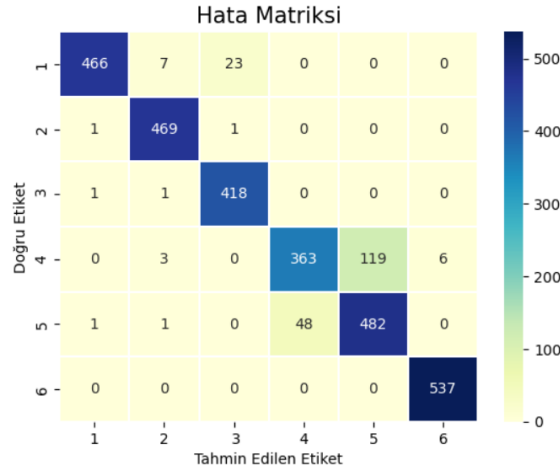
Aktiviteler: 1-Yürüme, 2-Merdiven Çıkma, 3-Merdiven İne, 4-Oturma, 5-Ayakta Durma, 6-Yatma

Şekil 6: Hata Matrisi 3

Dördüncü senaryoda ise gizli katmandaki ve tam bağlantı katmanındaki nöron sayıları artırılmıştır; gizli katmandaki nöron sayısı 150, epoch sayısı: 20 ve batch_size değeri: 64'tür. Loss değeri 0.262, doğruluk oranı ise 0.928 olmuştur. 4. Senaryonun loss fonksiyonu/doğruluk grafiği ve hata matrisi aşağıdaki gibidir.



Şekil 7: Eğitim Süreci Grafiği 4



Aktiviteler: 1-Yürüme, 2-Merdiven Çıkma, 3-Merdiven İnie, 4-Oturma, 5-Ayakta Durma, 6-Yatma

Şekil 8: Hata Matrisi 4

D. Sonuçlar

İnsan aktivitelerinin derin öğrenme modelleri kullanılarak tahmin edilebilmesi hem sağlıklı yaşam için hem de kronik hastalığı olan bireyler için oldukça önemlidir. Telerehabilitasyon yaklaşımlarının hız kazandığı günümüzde kişilerin evlerinde hangi egzersizleri yaptığını tespit edilmesi tedavi sürecine doğrudan katkı sağlayacaktır.

Çalışmamızda bu konu üzerine 6 farklı hareketin tespit edilebilmesi üzerine çalışılmıştır. LSTM modeli kullanılarak oluşturulan 4 farklı senaryo içerisinde en yüksek doğruluk oranı (0.928) son senaryoda gerçekleşmiştir. Gizli katmandaki ve tam bağlantı katmanındaki nöron sayıları artırılması tahmindeki doğruluk oranını artırırken, epoch ve batch_size değerindeki artış tahmindeki doğruluk oranının azalmasına neden olmuştur.

Tüm senaryoların hata matrisleri incelendiğinde yanlış tahminlerin dördüncü ve beşinci harekette yoğunlaştığı görülmektedir. Bunun altında yatan nedenin hem otur hem de ayakta durma pozisyonunda akselerometreden gelen verilerin birbirine çok benzer olduğu düşüncesidir.

Kaynakça

- [1] Jacobs, D.R., Jr.; Ainsworth, B.E.; Hartman, T.J.; Leon, A.S. A simultaneous evaluation of 10 commonly used physical activity questionnaires. *Med. Sci. Sport. Exerc.* 1993, 25, 81–91.
- [2] Vienne-Jumeau, A.; Oudre, L.; Moreau, A.; Quijoux, F.; Edmond, S.; Dandrieux, M.; Legendre, E.; Vidal, P.P.; Ricard, D. Personalized template-based step detection from inertial measurement units signals in multiple sclerosis. *Front. Neurol.* 2020, 11, 261.
- [3] Oudre, L.; Barrois-Müller, R.; Moreau, T.; Truong, C.; Vienne-Jumeau, A.; Ricard, D.; Vayatis, N.; Vidal, P.P. Template-based step detection with inertial measurement units. *Sensors* 2018, 18, 4033.
- [4] Foerster, F.; Smeja, M.; Fahrenberg, J. Detection of posture and motion by accelerometry: A validation study in ambulatory monitoring. *Comput. Hum. Behav.* 1999, 15, 571–583.
- [5] Lockhart, T.E.; Soangra, R.; Zhang, J.; Wu, X. Wavelet based automated postural event detection and activity classification with single IMU. *Biomed. Sci. Instrum.* 2013, 49, 224–233.
- [6] Ayachi, F.S.; Nguyen, H.P.; Lavigne-Pelletier, C.; Goubault, E.; Boissy, P.; Duval, C. Wavelet-based algorithm for auto-detection of daily living activities of older adults captured by multiple inertial measurement units (IMUs). *Physiol. Meas.* 2016, 37, 442–461.
- [7] Reiss, A.; Stricker, D. Introducing a new benchmarked dataset for activity monitoring. In *Proceedings of the 2012 16th International Symposium on Wearable Computers (ISWC)*, Newcastle, UK, 18–22 June 2012; pp. 108–109.
- [8] Ojeda, L.; Borenstein, J. Non-GPS navigation for security personnel and first responders. *J. Navig.* 2007, 60, 391–407.
- [9] Xu, J.Y.; Chang, H.-I.; Chien, C.; Kaiser, W.J.; Pottie, G.J. Context-driven, prescription-based personal activity classification: Methodology, architecture, and end-to-end implementation. *IEEE J. Biomed. Health Inform.* 2014, 18, 1015–1025.
- [10] Ravi, D.; Wong, C.; Lo, B.; Yang, G.-Z. A deep learning approach to on-node sensor data analytics for mobile or wearable devices. *IEEE J. Biomed. Health Inform.* 2017, 21, 56–64.

- [11] Ronao, C.A.; Cho, S.-B. Human activity recognition with smartphone sensors using deep learning neural networks. *Expert Syst. Appl.* 2016, 59, 235–244.
- [12] Eyobu, O.S.; Kim, Y.; Han, D.S. Activity Recognition for Infant Health Care Based on Wireless Inertial Measurement Unit Motion Data. In *Proceedings of the Korean Institute of Communication Sciences Conference, Jeju, Korea, 21–23 June 2017*; p. 436.
- [13] Yang, J.; Zhang, D.; Frangi, A.F.; Yang, J.-Y. Two-dimensional PCA: A new approach to appearance-based face representation and recognition. *IEEE Trans. Pattern Anal. Mach. Intell.* 2004, 26, 131–137.
- [14] Mao, A.; Ma, X.; He, Y.; Luo, J. Highly portable, sensor-based system for human fall monitoring. *Sensors* 2017, 17, 2096.
- [15] Pierleoni, P.; Belli, A.; Palma, L.; Pellegrini, M.; Pernini, L.; Valenti, S. A high reliability wearable device for elderly fall detection. *IEEE Sensors J.* 2015, 15, 4544–4553.
- [16] Bruno, B.; Mastrogiovanni, F.; Sgorbissa, A. Wearable inertial sensors: Applications, challenges, and public test benches. *IEEE Robot. Autom. Mag.* 2015, 22, 116–124.
- [17] Bert, F.; Giacometti, M.; Gualano, M.R.; Siliquini, R. Smartphones and health promotion: A review of the evidence. *J. Med. Syst.* 2014, 38, 9995.