



İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım

İbrahim Ali Metin^{1*}, Bahadır Karasulu²,

¹Çanakkale Onsekiz Mart Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Çanakkale, Türkiye

²Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Çanakkale, Türkiye

Özet

Bireyler üzerinden istenildiği anda insan aktivitelerini sınıflandırma ve tanıma sistemleri ile bilgi elde edilebilmektedir. Bu sistemler hastalıkların tespiti, fizik tedavi aşamalarının iyileştirilmesi, akıllı ev projelerinin geliştirilmesi gibi farklı alanlarda kullanılmaktadır. Bu çalışmada akıllı telefonlardaki ivme ölçer ve jiroskop duyarlarından elde edilmiş halkın kullanımına açık bir veri kümesinden alınan veriler kullanılmıştır. Literatürdeki çalışmaların çoğu yapay sinir ağı modeliyle zaman serilerinin işlenmesine dayanan daha yüksek seviyeli öznitelikleri ve bunların aralarındaki ilişkileri çözümlememektedir. Uzun-Kısa Süreli Bellek (UKSB) modeli tekrarlayan sinir ağı olarak hem zaman serileri için ilişki elde edebilmesi hem de katmanlar halinde kullanılabilen esnek yapısı nedeniyle oldukça uygun bir derin öğrenme yaklaşımıdır. Bu altyapıyı içeren derin öğrenme tabanlı yaklaşım çalışmamızdaki deneylerde çeşitli insan aktivitelerinin sınıflandırılmasında kullanılmıştır. Deneylerde farklı girdi parametreleri, katman ve ağ birimleri ilgili ağ modellerine verilerek sınıflandırma başarımları doğruluk oranı ölçülmüştür. Sonuçta yaklaşık %86 ilâ %93 arasında sınıflandırma başarımları elde edilerek altı farklı sınıfın yüksek doğrulukta sınıflandırıldığı gösterilmiştir. Çalışmada buna dair tartışma ve elde edilen bilimsel bulgulara da yer verilmektedir.

Anahtar Kelimeler: İnsan Aktiviteleri, Derin Öğrenme, Uzun-Kısa Süreli Bellek

Deep Learning-based Approach using Recurrent Neural Network for Classification of the Human Activities

Abstract

Information can be obtained through classification and recognition systems of human activities at any time. These systems are used in different areas such as disease detection, improvement of physical therapy stages, development of smart home projects, and etc. In this study, data taken from a public data set obtained from accelerometer and gyroscope sensors in smart phones were used. Most of the studies in the literature cannot analyze higher level attributes and their relationships based on time series processing with artificial neural network model. The Long-Short Term Memory (LSTM) model is a very suitable deep learning approach due to its ability to obtain relationships for time series as a recurrent neural network and to be flexible in its layers. The deep learning-based approach that includes this infrastructure has been used in the classification of various human activities in our

* İletişim e-posta: ibrahimalimetin@gmail.com

** Bu makale çalışmasının bir kısmı ICONDATA 2019 konferansında sözlü olarak sunulmuştur.

experiments. In the experiments, different input parameters, layer and network units were given to related network models and classification performance accuracy rate was measured. As a result, a classification performance of approximately 86% to 93% was obtained, showing that six different classes were classified with high accuracy. Discussion and scientific findings are also included in the study.

Keywords: Human Activities, Deep Learning, Long-ShortTerm Memory

1 Giriş

Sürekli gelişmekte olan günümüz teknolojilerinde, insanların bilgisayarlar ile olan bağlılığının çoğalması sebebiyle İnsan Aktivitelerinin sınıflandırılması önemli araştırma konuları arasına girmiştir [1, 2]. Yapılan çalışmalarda İnsan Aktivitelerinin Tanınması ile insan davranışları konusunda bilgi edinmek amaçlanmıştır [3]. Aktivite tanımda veriler genellikle dış ortam duyarga cihazlarından ya da giyilebilir duyargalar (wearable sensors) tarafından elde edilirler. Ortam duyargaları ile elde edilen veriler vücut hareketleri ile ilgili bilgi vermesine rağmen araştırmacıların ayrıntılı inceleme yapmasına olanak sağlayamamışlardır [4]. İvme duyargaları kullanımlarının kolay oluşu, ölçüm sonuçlarında sayısal değer alınabiliyor olması, maliyetlerinin uygun olduğu ve günlük hayatta kullanılabilirliği bu cihazları ortam duyargalarına göre daha ön planda tutulmasını sağlamıştır [5, 6]. İvme duyargaları kullanılarak insanların gün içerisinde gerçekleştirdikleri hareketlerin tespit ve sınıflandırılması konusunda birçok başarılı çalışma gerçekleştirilmiştir [7, 8]. Toplanan bilgilerin sonrasında makine öğrenmesi algoritmaları ile işlenerek olayların tanımlanması yapılmaktadır. İnsan aktivitelerinin sınıflandırılması; hastalık teşhisi, rehabilitasyon tedavi süreci, akıllı ev sistemlerinin projelendirilmesi, ortam koşullarının iyileştirilmesi ve otomatikleştirilmesi gibi birçok alanda kullanılmaktadır [9, 10].

Literatür incelendiğinde insan aktivitelerin sınıflandırılması konusunda farklı makine öğrenmesi yöntemleri ve duyargalar kullanıldığı görülmektedir. İnsan vücuduna yerleştirilen üç eksenli ivmeölçer ile uzanma, ayakta durma, koşma ve yürüme aktivitelerinin sınıflandırılması konusunda yüksek doğruluk oranı ile başarımlar sağlandığı görülmektedir [11]. Farklı bir çalışmada ise ayakta durma, yürüme, koşma, merdiven inme, merdiven çıkma, temizlik yapma, diş fırçalama ve oturma olarak adlandırılan sekiz eylemin değişik yöntemler ile sınıflandırmalarındaki doğruluk performansları değerlendirilmiştir [12].

Çalışmamızda ele aldığımız konuya benzer olarak akıllı telefonların ivmeölçer, jiroskop ve manyetometre duyargalarından toplanan veriler ile insan hareketlerinin sınıflandırılması De la Vega vd. çalışmasında başarıyla gerçekleştirilmiştir [13]. Akıllı telefonların dâhili ivmeölçer, jiroskop ve GPS duyargası verilerini alarak; yürüme, koşma, bisiklet sürme, araba veya otobüs ile seyahat etme eylemlerini altı farklı makine öğrenmesi yöntemi ile test edilmesi sonrasında en yüksek doğruluk oranı Rassal Orman (Random Forest) yöntemi ile kazanılmıştır [14].

Bu çalışmada, üç eksenli ivmeölçer ve jiroskop içerisinde bulunan bir akıllı telefon verileri ile derin öğrenme mimarisi modeli olan Uzun-Kısa Süreli Bellek (Long-Short Term Memory (UKSB-LSTM)) aracılığıyla insan aktivitelerinin sınıflandırılması yaklaşımı geliştirilmiştir. İvmeölçer verisi olarak halka açık kullanılan bir veri kümesi kullanılmıştır. Makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2 'de insan aktivite algılama için gerekli giyilebilir duyargalar hakkında bilgi verilmektedir. Bölüm 3 'de insan aktivitelerinin sınıflandırılmasındaki altyapı ve kullanılan yapay sinir ağlarının detayları açıklanmıştır. Bölüm 4 'de geliştirilen uygulama ile yapılan deneylerden elde edilen sonuçlara yer verilirken, Bölüm 5 'de ise bulgulara dayanan tartışma sunulmaktadır.

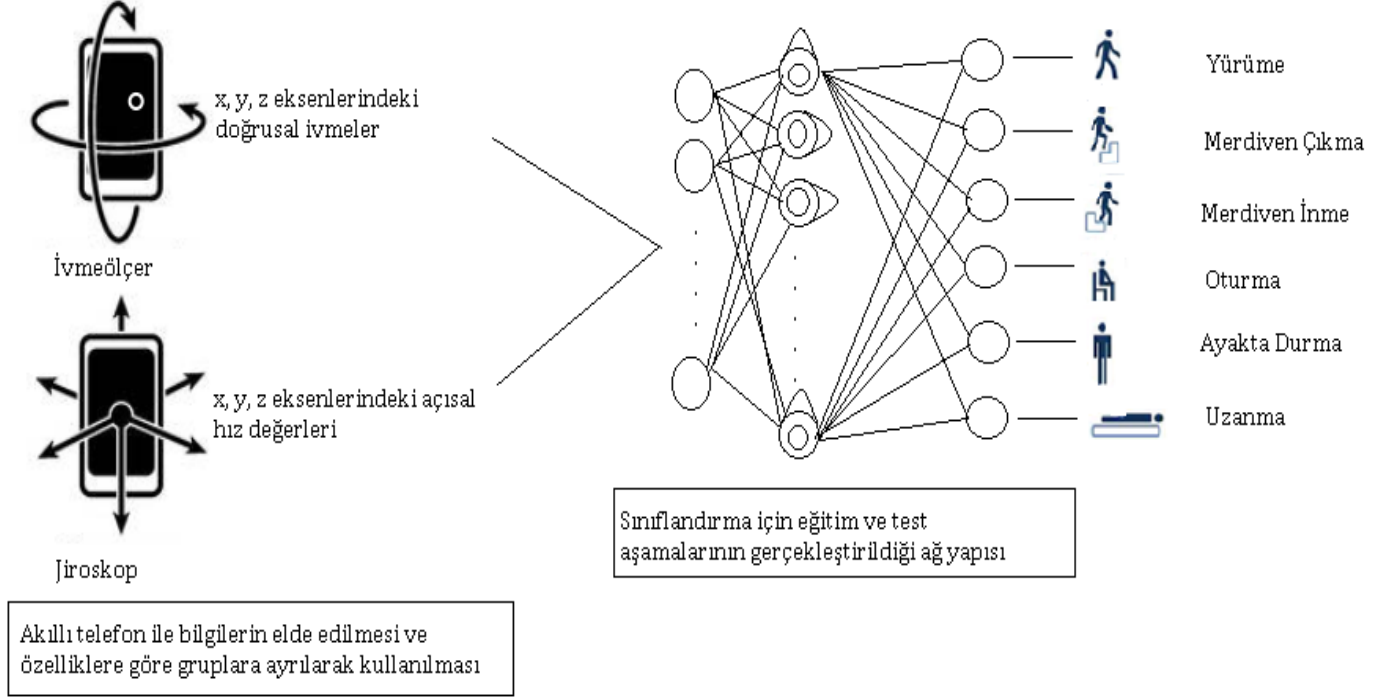
2 İnsan Aktivitesi Algılama

2.1 İnsan Aktivitesi

İnsan aktivitesi sınıflandırma sistemleri, insanlardan elde edilen veriler ile içerisinde bulunan çevrenin tanımlanmasıyla gerçekleştiriliyor olan hareketin belirtilmesini hedefler [15]. Bu sayede kişi hakkında istenildiğinde bilgi elde edilebilir. İnsan hareketleri genel olarak; kısa olaylar, temel aktiviteler ve karmaşık aktiviteler olmak üzere üç ana gruba ayrılmaktadır. Kısa aktiviteler olarak isimlendirilen hareketlere örnek verilecek olursa; oturma pozisyonundan diğer bir pozisyona geçiş olarak adlandırılabilirken, yürüyüş yapmak ise temel bir aktivitedir [16]. Son olarak farklı nesne ve bireyler

ile birliktelik içerisinde gerçekleştirilen hareketler ise karmaşık hareketlerdir [17]. Enstrüman çalmak ve çeşitli spor hareketleri karmaşık aktivite grubuna örnektir [18]. Bu çalışmada temel aktiviteler grubu içerisindeki hareketlerin sınıflandırılması gerçekleştirilmiştir. Bu aktivite grubu içerisinde 6 temel hareket belirtilmiştir.

Bunlar; ayakta durma, uzanma ve oturma aktivitelerini içerisinde barındıran üç adet statik aktivite ile yürüme, merdiven inme ve çıkma aktivitelerini barındıran üç adet de dinamik aktiviteyi içermektedir [16]. Gerçekleştirilen yapının temel açıklaması Şekil 1'de gösterilmektedir.




Şekil 1. İnsan aktivitesi sınıflandırma altyapısı [19]

2.2 Giyilebilir Duyargalar

Akıllı telefonlar içerisinde insan aktivitesi sınıflandırılması için çoğunlukla tercih edilen ivmeölçer ve jiroskop yer almaktadır. Bu şekilde kullanımı kolay ve yaşam standartlarına uygundur [20]. Telefon içerisinde 3-eksenli ivmeölçer ile 3-eksenli jiroskopun bulunduğu açısal ölçüm duyargası yer almaktadır. Aktivitenin doğrusal ivme değerini ivmeölçer, eksen etrafında dönmesinden ortaya çıkan açısal hızı ise jiroskop ölçmektedir.

2.2.1 İvmeölçer


İvmeölçer 3-eksen boyunca kullanılan cihazın maruz kaldığı ivmenin ölçülmesini sağlar. 3-eksenli ivmeölçerin etki ettikleri yönler Şekil 2'de gösterilmektedir [21]. İvmelenme bilgileri zaman değerleri ile birlikte oluşmaktadır. Bu değer m/s^2 türünde bir veridir. Bu duyargaların sundukları veriler yerçekimi kuvveti ve doğrusal ivmedir [22].



Şekil 2. İvmeölçer algılayıcısı

2.2.2 Jiroskop

Aktivite sınıflandırılmasında yön tayini ve değişikliklerinin belirlenmesinde kullanılan giyilebilir duyargalardan jiroskop Şekil 3'te görüldüğü üzere x, y, z eksenlerinde elde edilen açısal hız değerlerini belirtmektedir. Belirtilen fiziksel eksenler etrafında dönme hareketi rad/s (radyan/saniye) türünden gösterilmektedir [23].



Şekil 3. Jiroskop algılayıcısı


3 İnsan Aktivitelerini Sınıflandırma

Literatürde gerçekleştirilen sistemlerin incelenmesi sonrasında insan aktivitelerinin sınıflandırılması için ortam duyargaları ve giyilebilir cihazlardan elde edilen duyarga bilgilerinin makine öğrenmesi teknikleri kullanılarak çıkarsama yaptığı gözlemlenmektedir. Bu bölümde çalışmada kullanılan derin öğrenme yöntemlerinden bahsedilmiştir. Bu yöntemlerden Tekrarlayan Sinir Ağları (Recurrent Neural Network (TSA-RNN)) ve Uzun-Kısa Süreli Bellek (Long-Short Term Memory, (UKSB-LSTM)) hücreleri zaman serilerini kullanırlar. Zaman serileri ham verilerin zaman birimlerinin aralıklarında elde edilen ölçümlere göre oluşturulan dizilerdir [23]. Ülkemizin 20 yıllık doğal gaz tüketim değerleri zaman serisine örnek verilebilir. Değişkenler bir zaman aralığı üzerinde ölçülen değerlerini ve bunların farklı değişkenler ile karşılaştırılmasıyla zaman serisi analizi (time series analysis) yapılmaktadır. Zaman değişkenlerinde bağımlılık ilişkisi vardır [24]. Bağımlı değişkenler bir diğer değişkenin değersel artış veya azalışlarına göre değişim gösteren değişkenlerdir. Bağımsız değişkenler diğer değişkenlerdeki değişimlerden etkilenmezler, çoğunlukla girdi değişkenleri bağımsız değişken tipindedir. Çıktı değişkenleri girdi değişkenlerine bağlı olduğu için (örneğin x girdisine karşılık y elde edilir) bağımlı değişken tipindedir [25].

3.1 Tekrarlayan Sinir Ağları (Recurrent Neural Network (TSA-RNN))

Yapay sinir ağlarının bir türü olan TSA, çıktı verilerinin sinir ağının ardışık, zaman serisi girdilerinin hesaplanması sonucuna bağlıdır. TSA ileri beslemeli ağlardan farklı bir şekilde, girdi

verilerini işleme alırken kendi hafızalarından yararlanmaktadırlar. TSA, el yazısı, konuşma ve aktivite sınıflandırmaları benzeri uygulama alanlarında zaman serisi verilerinin işlenmesini gerçekleştirmektedir [26]. Şekil 4 'de TSA açılımı görüntülenmektedir.



Şekil 4. TSA açılımı [27]

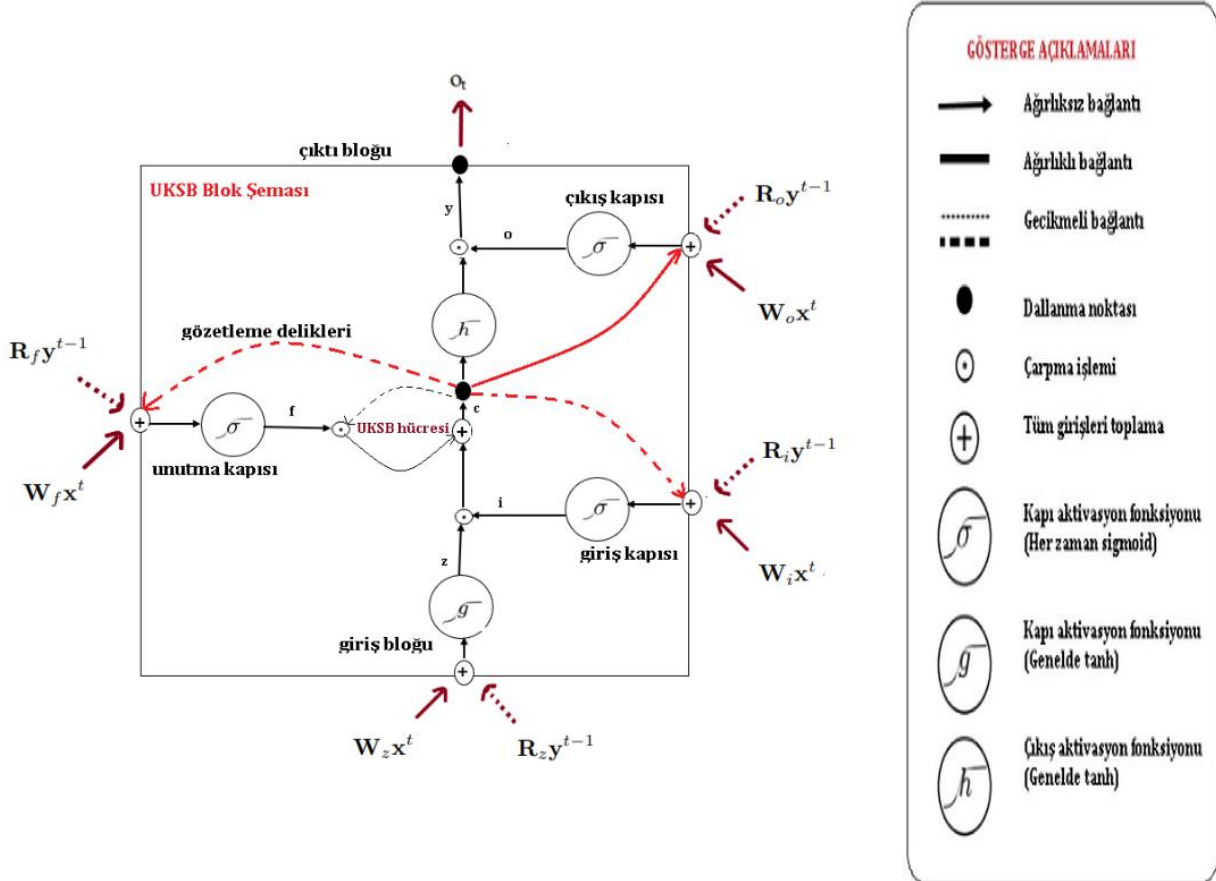
TSA eğitiminde; alışlagelmiş sinir ağlarında olduğu gibi geri yayılım (Backpropagation) yapılması gerekmektedir. Bu durumda da TSA 'nın getirdiği büyük bir sorun ortaya çıkmaktadır. Gradyan tüm ağırlıkları ayarlamamızı sağlayan değerdir. Sinir ağı verileri tüm katmanlarda kullanıldığından her bir çıktıdaki Gradyan yalnızca o anki katmana değil de bir önceki katmana da bağlıdır. Birden fazla zaman aralığında geri yayılım işlemi sürekli yenilenir ise sonuç küçülmekte ve de kaybolan Gradyan problemi ortaya çıkmaktadır. Aynı durumda Gradyanlar birden büyük ise sonuç büyür ve patlayan Gradyan problemi ortaya çıkar. Bu duruma çözüm olarak UKSB mimariler geliştirilmiştir.

3.2 Uzun-Kısa Süreli Bellek (Long-Short Term Memory (UKSB-LSTM))

İlk olarak 1997'de Juergen Schmidhuber tarafından önerilen UKSB hücreleri, kaybolan gradyan ve uzun vadeli bağımlılık problemlerine çözüm üretmek amacıyla geliştirilen TSA 'nın bir türüdür. Zaman serilerinde TSA 'a göre daha tutarlı ve daha iyi performans sağlayan özel iç kapılara (unutma kapısı (forget gate)) sahiptirler. Evrişimli Sinir Ağları (Convolutional Neural Network (ESA-CNN)), Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines (KBM-RBM)) ve otomatik kodlayıcı (Auto Encoder) gibi diğer ağların yapısı ile karşılaştırıldığında, UKSB 'nin yapısı; özellikle doğal dil işleme, konuşma tanıma ve hava durumu tahminleriyle ilgili olaylar gibi zaman serileri içeren problemleri çözmede oldukça başarılıdır. Çünkü ağ tasarımı gradyanların zaman boyunca kolayca akmasını sağlar [28]. UKSB hücreleri girdi verilerini uzun süreler hafızada tutma işlemi sergilemektedir.

UKSB hücrelerinin genel olarak TSA 'ları ile mimarileri aynıdır; fakat gizli durumu hesaplamak için farklı bir fonksiyon kullanılmaktadır. UKSB hücrelerinin hafızaları önceki durum verileri ile o anki mevcut giriş verilerini sonraki durum için girdi olarak kullanmaktadır. Bu hücreler, hafızalarında hangi verileri tutacaklarına (ya da hangi verileri sileceklerine) karar verirler. Bu işlemler sonrasında önceki durum verileri, o anki hafızada bulunan verileri ve girdi verilerini birleştirirler. UKSB

hücrelerinin uzun vadeli bağımlılıkları öğrenmede oldukça etkili bir yöntem oldukları deneylerle gözlemlenmektedir. Şekil 5'de UKSB hücrelerinin ayrıntılı blok şeması görülmektedir. Şekilde verilen W terimleri ağırlıkları, R terimleri tekrarlayıcı ağırlıklarını göstermektedir. Ayrıca x^t girdi vektörü t zamanına göre verilen bir zaman serisidir. Diğer terimler olarak z girdi bloğunu, i girdi kapısını, f unutmama kapısını, o çıktı kapısını, c terimi hücreyi ve y terimi çıktı bloğunu göstermektedir.



Şekil 5. UKSB hücrelerinin blok şeması [29]

4 Uygulama

4.1 Veri Kümesi

Makalemizde gerçekleştirilen çalışmada kullanılan duyarga verileri, kullanıma açık veri kümesi olan UCI veri kümesi deposundan alınmıştır [30, 36]. Verilerin elde edilme deneylerinde gönüllü 30 kişinin bellerine ivme ölçer ve jiroskop verileri bulunan akıllı telefon takılarak sınıflandırılması yapılacak 6 aktivitenin yapılması gerçekleştirilmiştir. Bunlar İngilizce terimleriyle sırayla; "Walking (Yürüme)", "Walking_Upstairs (Merdiven çıkma)", "Walking_Downstairs (Merdiven inme)", "Sitting (Oturma)", "Standing

(Ayakta durma)", "Laying (Uzanma)" olarak veri kümesinde etiketlenmişlerdir. İvmeölçer ve Jiroskop duyargaları kullanılarak üç eksenli doğrusal gövde ile yerçekimi ivmeleri (tAcc - XYZ) ve üç eksenli açılma hızı (tGyro - XYZ) sinyalleri elde edilmiştir. Bu duyarga sinyalleri gürültü filtreleri uygulanarak ön işleme tabi tutulur ve daha sonra her biri 50 Hz. frekansında 2.56 saniyelik sabit genişlikli pencerelerde örneklenmektedir. Her pencerede 128 okuma gerçekleştirilmektedir. Elde edilen normalize edilmiş 9 sinyal verisine ("body_acc_x_", "body_acc_y_", "body_acc_z_", "body_gyro_x_", "body_gyro_y_", "body_gyro_z_", "total_acc_x_", "total_acc_y_", "total_acc_z_") 17 farklı

öznitelik fonksiyonu ('mean()', 'mad()', 'max()', 'sma()' vb...) uygulanarak 561 öznitelikten oluşan bir öznitelik vektörü oluşturulmuştur. Bu vektördeki verilerin normalize edilmesi gerekmiştir. Vektör değerleri [-1, 1] aralığı için normalize edilmiştir. Deneylerdeki 30 kişiden elde edilen toplam 10299 verinin %70 'i olan 7352 adet veri eğitim için, 2947 veri ise %30 'luk kalan kısım olarak test için kullanılmıştır [36].

4.2 Deneysel Sonuçlar

Makaledeki çalışmada geliştirilen uygulama, derin öğrenme alt yapısını oluşturmak için Python [31] programlama dili versiyon 3.7 kullanılarak geliştirilmiştir. Bu işlemler için bir Python dilini destekleyen veri bilimi platformu olan Anaconda [32] kullanılmıştır. Anaconda derin öğrenme mimarileri için gerekli birçok kütüphaneyi

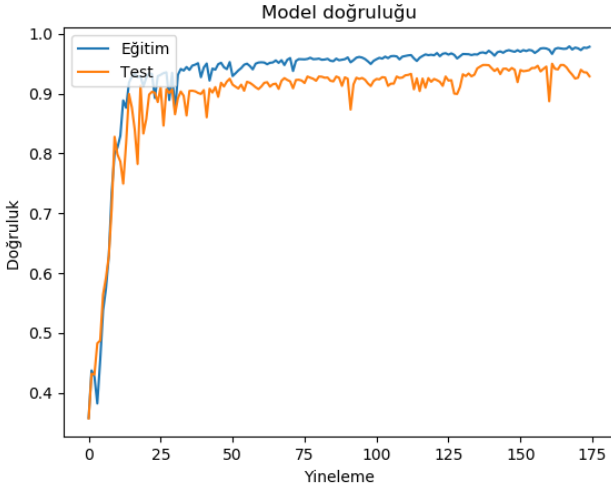
içerisinde barındırdığından ayrıca kütüphanelerin ve Python programlama diline dair ek yüklemelerine gerek kalmamıştır. Kodların yazılması PyCharm [33] geliştirme ortamında (IDE) gerçekleştirilmiştir. Geliştirilen model için derin öğrenme kütüphanesi olan Tensorflow 1.14 [34] ile uygulama programlama arayüzü (API) Keras 2.2.4 [35] kullanılmıştır. Yapılan deneylerde şu tipte parametreler; eğitim yineleme sayısı, girdi verilerinin parçalar halinde işleme alınacağı boyut (Mini-Batch), çıktı birim sayısı, girdi birim sayısı, adım zaman (timestep) başına verilen giriş parametresi ve aktivasyon fonksiyonu kullanılmıştır. Aşağıdaki Tablo 1 'de yapılan deneyler sırasında ilgili parametrelerin ilgili derin öğrenme modeli ile kullanıldığında elde edilen test kayıp ve doğruluk değerleri yer almaktadır.

Tablo 1. Farklı parametreler ile elde edilen sonuçlar

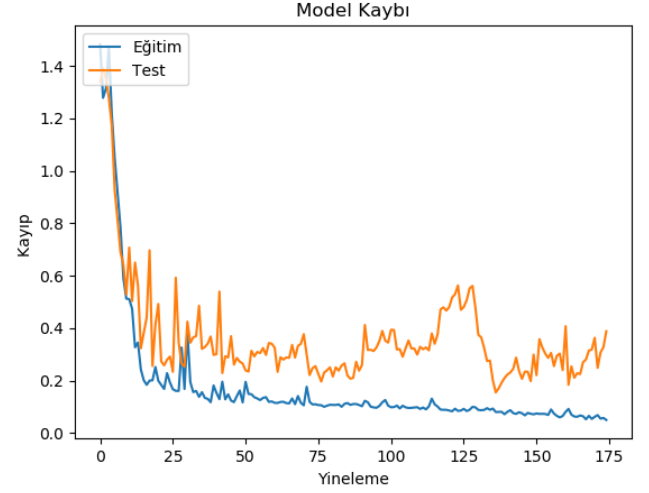
Deney No	Girdi Birim Sayısı	Çıktı Birim Sayısı	Katman Yapısı	Eğitim Yineleme Sayısı (Epochs)	Girdi Verisinin Parçalanma Boyutu (batch_size)	Test Kaybı (Loss)	Test Doğruluğu (Accuracy) (%)
1	9	32	UKSB (32) + Tam Bağlı (6)	320	16	0,434032	91,957923
2	9	32	UKSB (32) + Tam Bağlı (6)	30	16	0,37397	87,546658
3	9	100	UKSB (100) + Tam Bağlı (6)	40	40	0,279103	89,37903
4	9	128	UKSB (128) + Tam Bağlı (6)	175	32	0,388113	92,908042
5	9	128	UKSB (128) + Tam Bağlı (6)	50	36	0,473168	86,359009

Tablo 1'de görüldüğü gibi koyu rakamlar ile gösterilen dördüncü deneydeki parametreler kullanıldığında UKSB modelinde %92,91 eğitim doğruluğuna ulaşıldığı yapılan deneyler ile görülmüştür. Belirtilen parametreler için deneyler HP ProBook 450 G4 model bilgisayar (i7 Intel 2.7GHz işlemci ve 8 GB Bellekli) ile gerçekleştirilerek Şekil 6 ve Şekil 7 'de belirtilen model kaybı ve model doğruluğu başarımları sonuç grafikleri elde edilmiştir. Doğruluk değerlerinin yaklaşık yirmi beşinci yinelemeden sonra stabil olarak %88 ilâ %93 arasında değişim gösterdiği görülmektedir. Tablo 2 'de ise sınıflandırılma çalışması yapılan 6 insan aktivitesinin karmaşıklık

matrisi yer almaktadır. Belirtilen matriste satır değerleri test edilen modelin gerçek sınıf aktivite sayılarını belirtmektedir. Sütun verileri ise tahmin edilen sınıf aktivite sayılarını belirtmektedir. Uzanma (537) ve ayakta durma (500) aktiviteleri için oldukça iyi sınıflandırma yapıldığı görülmektedir. Literatürdeki çalışmaların çoğu yapay sinir ağı modeli zaman serilerinin işlenmesine dayanan daha yüksek seviyeli öznitelikleri ve bunların aralarındaki ilişkileri çözümleyememektedir. UKSB hem bu açıdan hem de katman sayısı ve gerekli düğüm adetleri açısından oldukça uygun bir alternatiftir.



Şekil 6. Model doğruluk grafiği



Şekil 7. Model kayıp grafiği

Tablo 2. Karmaşıklık matrisi

SONUÇ \ HEDEF		Tahmin edilen sınıf					
		YÜRÜME	MERDİVEN ÇIKMA	MERDİVEN İNME	OTURMA	AYAKTA DURMA	UZANMA
Gerçek sınıf	YÜRÜME	489	3	4	0	0	0
	MERDİVEN ÇIKMA	4	462	4	1	0	0
	MERDİVEN İNME	6	23	391	0	0	0
	OTURMA	0	1	0	359	125	6
	AYAKTA DURMA	1	0	0	31	500	0
	UZANMA	0	0	0	0	0	537

Tablo 3. Literatürdeki benzer çalışmaların başarımların karşılaştırması

Çalışma No	Çalışmada Kullanılan Mimari	Çalışmada Kullanılan Veri Kümesi	Çalışma Yılı	Test Doğruluğu (Accuracy) (%)	Referans
1	ESA + Veri önileme	UCI	2018	97.63	[37]
2	ESA	UCI	2015	95.18	[38]
3	Çift Yönlü UKSB	UCI	2018	93.60	[39]
4	UKSB	UCI	2019	92.91	Bizim çalışmamız
5	Rassal Orman	UCI	2015	77.81	[40]

Tablo3 'de en yüksek değer ESA modeli için gözükmeyle beraber, bu modelin yanı sıra veri önışleme yapılması nedeniyle modelin saf halinin kullanımı yerine başarımı artırıcı müdahalelerde bulunulduğu görülmektedir. Çalışmamızdaki sonuca en yakın sonuç Çift Yönlü UKSB ile elde edilen başarımlar sonucudur. Bunun başlıca nedeni bizim çalışmamızdaki modelin saf haliyle UKSB içermiş olması, Zhao vd. [39] çalışmasının ise veri üzerinden çift yönlü (ileriye ve geriye doğru) geçiş yaparak daha yüksek seviyeden anlamsallığa ulaşmış olmasıdır. Bu çift yönlü geçiş hesapsal karmaşıklığı artırmakta ve daha fazla yer karmaşıklığına da neden olmaktadır. Bu açıdan çalışmamız UKSB tipi modeller için en etkin çözümlerden biri olarak ön plana çıkmaktadır.

5 Sonuç

Bu çalışmada akıllı telefonların içerisinde yer alan ivmeölçer ve jiroskop verilerinin toplanması ile oluşturulmuş veri kümesi ile oluşturulan UKSB hücrelerinin 6 insan aktivitesinin sınıflandırılması için eğitim ve testleri gerçekleştirilmiştir. Bu testlerde UKSB hücrelerine farklı girdi parametreleri verilerek en yüksek değer olarak %92,91 başarımlar oranı elde edilmiştir.

UKSB diğer yapay sinir ağları (örneğin çok katmanlı algılayıcı (multilayer perceptron)) ile kıyaslandığında veri kümesinden öznitelikleri otomatik olarak işleyebilmesi ve zamansal ilişkiyi otomatik olarak çözümlenebiliyor oluşu nedeniyle ön plana çıkmaktadır. Çalışmamızda bu nedenlerden dolayı UKSB tercih edilmiştir.

Kaynaklar

- [1] Chen Y, Shen C. "Performance analysis of smartphone-sensor behavior for human activity recognition". IEEE Access 5, 3095-3110, 2017.
- [2] Campbell A, Choudhury T. "From smart to cognitive phones". IEEE Pervasive Comput. 11 (3), 7-11, 2012.
- [3] Clarkson B.P. Life patterns: Structure from wearable sensors (Ph.D. thesis), Massachusetts Institute of Technology, 2002.
- [4] Zhang Z, Ji L, Huang Z, Wu J. "Multi-Model Adaptation for Thigh Movement Estimation Using Accelerometers". IET Signal Processing, 5:709-716, 2011.
- [5] Muscillo R, Schmid M, Conforto S, D'Alessio T. "An Adaptive Kalman-Based Bayes Estimation Technique to Classify Locomotor Activities in Young and Elderly Adults Through Accelerometers". Medical Engineering & Physics, 32:849-859, 2010.

Kaybolan gradyan sorununun UKSB tarafından çözümlenmiş olması ağı eğitim aşamasında diğer klasik ve yalın ağ modellerine göre daha iyi sonuçlar elde etmesine ve buna uygun test işlemlerinde daha yüksek başarımlarda sonuçlar oluşturmaya neden olmaktadır. Literatürdeki ESA tipi ağ modelleri kendine özgü katman yapısı gereği otomatik olarak öznitelik elde etmeye daha yatkın olmaları ve yüksek seviyeden bilgiye çeşitli ara işlemler (biriktirme ve evrişim) sayesinde ulaşmaları nedeniyle UKSB ağ modeline göre bazı deneylerde daha yüksek başarımlar değerleri elde edebilmektedir. Bu tip ağların aksine UKSB ağ modeli ile zamansal ilişkiler daha doğru ve eksiksiz ortaya konulabildiği için ESA ağ modellerine göre daha uzun bağlam bloklarıyla uğraşabilmekte ve daha farklı bağlamda verileri işleyebilmektedir. Çift yönlü geçiş ile UKSB başarımlarını iyileştirilebilmekte, çeşitli zamansal ilişkiler daha tutarlı olarak tüm veri üzerinden elde edilebilmektedir.

Literatürdeki gerçekleştirilen çalışmalar incelendiğinde makalede kullanılan UCI veri kümesi ile farklı makine öğrenmesi modelleri kullanılarak sınıflandırma çalışmaları yapıldığı görülmektedir. Bu çalışmada gerçekleştirilen aktivite sınıflandırması literatürde yer alan yüksek doğrulukta sonuçlanmış çalışmalar arasında yer alacak başarımlarını göstermektedir.

- [6] Yang M, Zheng H, Wang H, McClean S, Newell D. "iGAIT: An interactive accelerometer based gait analysis system". Computer Methods and Programs in Biomedicine, 108:715-723, 2012.
- [7] Chung P.Y.M, Ng G.Y.F. "Comparison Between an Accelerometer and a Three-Dimensional Motion Analysis System for The Detection of Movement". Physiotherapy, 98:256-259, 2012.
- [8] Mathie M.J, Celler B.G, Lovell N.H, Coster A.C.F. "Classification of basic Daily movements using a triaxial accelerometer". Medical & Biological Engineering & Computing, 42:679-687, 2004.
- [9] Avci A, Bosch S, Marin-Perianu M, Marin-Perianu R, Havinga P. "Activity recognition using inertial sensing for healthcare, well being and sports applications: A survey". 23rd International Conference on Architecture of Computing Systems (ARCS), pp. 1-10, VDE 2010.
- [10] Lin W, Sun M.-T, Poovandran R, Zhang Z. "Human activity recognition for video surveillance". IEEE

- International Symposium on Circuits and Systems, 2737-2740, 2008.
- [11] Yang J.-Y, Wang J.-S, Chen Y.-P. "Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers". *Pattern recognition letters*, 29(16), 2213-2220, 2008.
- [12] Ravi N, Dandekar N, Mysore P, Littman M.L. "Activity recognition from accelerometer data". *AAAI*, 5, 1541-1546, 2005.
- [13] De la Vega L.G.M, Raghuraman S, Balasubramanian A, Prabhakaran B. "Exploring unconstrained mobile sensor based human activity recognition". 3rd International Workshop on Mobile Sensing, 8-11, Philadelphia USA, 2013.
- [14] Sağbaş E.A, Ballı S. "Akıllı Telefon Algılayıcıları ve Makine Öğrenmesi Kullanılarak Ulaşım Türü Tespiti". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, Cilt 22, Sayı 5, Sayfalar 376- 383, Ocak 2016.
- [15] Wang J, Chen R, Sun X. "Generative models for automatic recognition of human daily activities from a single triaxial accelerometer". *WCCI 2012 IEEE World Congress on Computational Intelligence*, 10-15, June 2012.
- [16] Bao L, Intille S.S. "Activity recognition from user-annotated acceleration data". *Pervasive Computing*, 1-17, 2004.
- [17] Aggarwal K.K, Ryoo M.S. "Human activity analysis: A review". *ACM Computing Surveys*, 43 (3), 1-16, 2011.
- [18] Reyes-Ortiz J.L, Oneto L, Sama A, Parra X, Anguita D. "Transition-Aware Human Activity Recognition Using Smartphones", *Neurocomputing*, Volume 171 Issue C, Pages 754-767, January 2016.
- [19] Tural K, Akdoğan E. "Akıllı Telefonların Algılayıcılarının Verilerini Kullanarak Yapay Sinir Ağları ile İnsan Hareketlerinin Sınıflandırılması". *Otomatik Kontrol Ulusal Toplantısı TOK*, cilt.1, no.1, ss.479-483, İstanbul, Türkiye, 21-23 Eylül 2017.
- [20] Reyes-Ortiz J.L, Oneto L, Ghio A, Sama A, Anguita D, Parra X. "Human Activity Recognition on Smartphones with Awareness of Basic Activities and Postural Transitions". *Artificial Neural Networks and Machine Learning, ICANN, Lecture Notes in Computer Science*. 8681, 177-184, Springer 2014.
- [21] Su X, Tong H, Ji P. "Activity Recognition with Smartphone Sensors". *Tsinghua Science and Technology, International Journal of Information Science*, vol. 19, no. 3, pp. 235-249, 2014.
- [22] Sağbaş E.A, Ballı S. (2015) Akıllı Telefon Sensörlerinin Kullanımı ve Ham Sensör Verilerine Erişim. *Akademik Bilişim*, 158-164, Eskişehir, Türkiye, 4-6 Şubat 2015.
- [23] Gunduz H, Cataltepe Z. "Borsa Istanbul (BIST) daily prediction using financial news and balanced feature selection". *Expert Systems with Applications*, 42(22), 9001-9011, 2015.
- [24] Murata S, Namikawa J, Arie H, Sugano S, Tani J. "Learning to Reproduce Fluctuating Time Series by Inferring Their Time-Dependent Stochastic Properties: Application in Robot Learning via Tutoring". *IEEE Transactions on Autonomous Mental Development (JIF: 1.348)*, Vol. 5, Issue 4, pp. 298-310, 2013.
- [25] Özden C, Acı Ç. Analysis of injury traffic accidents with machine learning methods: Adana case. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 266-275, 2018.
- [26] Mikolov T, Karafiat M, Burget L, Cernocky J, Khudanpur S. "Recurrent neural network based language model". In *INTERSPEECH*, 1045-1048, 2010.
- [27] Feng W, Guan N, Li Y, Zhang X, Luo Z. "Audio visual speech recognition with multimodal recurrent neural networks". pp. 681-688, 2017.
- [28] Hochreiter S, Schmidhuber J. "Long-short term memory, *Neural computation*". 9(8), 1735-1780, 1997.
- [29] Greff K, Srivastava R.K, Koutnik J, Steunebrink B.R, Schmidhuber J. "LSTM: A Search Space Odyssey". *IEEE Transactions on Neural Networks and Learning Systems*, Vol 28, Issue 10, Pp 2222-2232, 2017.
- [30] UCI veri kümesi websitesi. "Human Activity Recognition Using Smartphones Data Set". <https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones>. (03.09.2019)
- [31] Python programlama dili websitesi. <https://www.python.org/>. (03.09.2019).
- [32] Anaconda Veri Bilimi Platformu websitesi. <https://www.anaconda.com/>. (03.09.2019).
- [33] PyCharm IDE websitesi. <https://www.jetbrains.com/pycharm/>. (03.09.2019).
- [34] Google Tensorflow API websitesi. <https://www.tensorflow.org/>. (03.09.2019).
- [35] Keras API websitesi. <https://keras.io/>. (03.09.2019)
- [36] Anguita D, Ghio A, Oneto L, Parra X, Reyes-Ortiz J.L. "A Public Domain Dataset for Human Activity Recognition Using Smartphones". *ESANN proceedings, European Symposium on Artificial Neural Networks, Computation a Intelligence and Machine Learning*. Bruges (Belgium), 24-26 April 2013, i6doc.com public, ISBN 978-2-87419-081-0. <http://www.i6doc.com/en/livre/?GCOI=28001100131010>.
- [37] Ignatov A. "Real-time human activity recognition from accelerometer data using Convolutional Neural Networks". *Applied Soft Computing*, Volume 62, 2018, Pages 915-922, ISSN 1568-4946, 2018. <https://doi.org/10.1016/j.asoc.2017.09.027>.
- [38] Jiang W., Yin Z., "Human activity recognition using wearable sensors by deep convolutional neural

- networks". In Proceedings of the 23rd ACM International Conference on Multimedia, pp. 1307-1310, 2015.
- [39] Zhao Y, Yang R, Chevalier G, Xu X, Zhang Z. "Deep Residual Bidir-LSTM for Human Activity Recognition Using Wearable Sensors". *Mathematical Problems in Engineering*, Article ID 7316954, 13 pages, 2018. <https://doi.org/10.1155/2018/7316954>.
- [40] Kolosnjaji B, Eckert C. "Neural network-based user-independent physical activity recognition for mobile devices". In Proceedings of the IDEAL: 16th International Conference, pp. 378-386, 2015.