



A novel dataset of human daily activities: Its benchmarking results for classification performance via using deep learning techniques

İbrahim Ali Metin^{1*}, Bahadır Karasulu²

¹ODAS Energy, Çan, Çanakkale, 17400, Turkey

²Department of Computer Engineering, Çanakkale Onsekiz Mart University, Çanakkale, 17100, Turkey

Highlights:

- A novel dataset consists of smartphone sensor data has been formed.
- Performance evaluation and comparison was done through the use of deep learning architectural models.
- For an objective performance benchmarking, a novel and unique software tool has been created.

Keywords:

- Human Activities
- Recurrent Neural Network
- Convolutional Neural Network
- Dataset
- Performance Evaluation

Article Info:

Research Article
Received: 23.07.2020
Accepted: 15.10.2020

DOI:

10.17341/gazimmfd.772849

Acknowledgement:

We thank to valuable ten volunteers that contributed to our experiments at data acquisition stage.

Correspondence:

Author: İbrahim Ali Metin
e-mail:
ibrahimalimetin@gmail.com
phone: +90 541 474 2693

Graphical/Tabular Abstract

In this study, a novel data set is presented to be used in classifying the activities that individuals perform during the day. Various deep architectural models presented in the study were tested on various classification experiments with publicly available datasets well-known in the literature and our proposed novel dataset. This dataset was created with the sensor data collected with the smartphone located onto the belly region of ten volunteer individuals consisting of five males and five females aged between 25 and 55 years. Data of each activity at two different positions were taken with 20 Hz sampling frequency for each activity position. In this scope, 15 seconds raw data including 4 dynamic and 3 static activities were acquired. Some kind of network configurations can be chosen during the experiments with the help of our novel and unique software tool by allowing different network parameters and layer selection for the deep learning architectures including recurrent neural network (RNN) models and convolutional neural network (CNN) model.




Figure A. Schematic for our novel dataset and its performance benchmarking with the use of software tool

Purpose: This study aims to prove the necessity and usefulness of proposed novel dataset of human daily activities, and also, it presents the performance benchmarking results for activity classification obtained with the use of proposed novel software tool.

Theory and Methods:

The proposed software tool uses convolutional neural network (CNN) model and recurrent neural network (RNN) models such as long-short term memory (LSTM) and gated recurrent unit (GRU), and also, bidirectional versions of these RNNs. Our novel dataset and other two dataset from literature were tested by using these abovementioned deep learning architectural models to prove the classification performance benchmarking capabilities of our software tool.

Results:

In this study, the classification performance achieved by deep learning architectural models varies with parameter configuration of these models in given experiments. In these experiments, the best accuracy rates are obtained between 97% and 99% for various activities of individuals taken from two different datasets and our novel proposed dataset as well. These kind of activities given in abovementioned datasets are walking, walking upstairs, walking downstairs, sitting, standing, laying, jogging and jumping.

Conclusion:

Our novel dataset consists of smartphone sensor data has been formed via compiling the raw and filtered signals for the classification task of human daily activities. Furthermore, it has been presented to the literature together with its alternative subsets. Proposed software tool presents the flexible experiment environment which allows experiments conducted with deep learning architectures to be easily performed with different network parameters and number of layers as well.



İnsanın günlük aktivitelerinin yeni bir veri kümesi: Derin öğrenme tekniklerini kullanarak sınıflandırma performansı için kıyaslama sonuçları

İbrahim Ali Metin^{1*} , Bahadır Karasulu²

¹ODAŞ Enerji, 17400, Çan, Çanakkale, Türkiye

²Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 17100, Çanakkale, Türkiye

Ö N E Ç İ K A N L A R

- Akıllı telefon duyarga verilerinden oluşan yeni bir veri kümesi oluşturulmuştur
- Başarım değerlendirme ve karşılaştırma derin öğrenme mimari modellerinin kullanımı yoluyla yapılmıştır
- Nesnel bir başarımlı kıyaslaması için yeni ve benzersiz bir yazılımsal araç oluşturulmuştur

Makale Bilgileri

Araştırma Makalesi
Geliş: 23.07.2020
Kabul: 15.10.2020

DOI:

10.17341/gazimmfd.772849

Anahtar Kelimeler:

İnsan aktiviteleri,
tekrarlayan sinir ağı,
evrişimli sinir ağı,
veri kümesi,
başarım değerlendirme

ÖZET

İnsan aktivitelerini sınıflandırma çalışmaları, bireylerin içinde buldukları ortam ile etkileşimini değerlendirerek günlük yaşamı kolaylaştıracak yeni sistemler geliştirilmesine katkı sağlayabilir. Bu çalışmada, bireylerin gün içerisinde gerçekleştirdikleri aktivitelerin sınıflandırılmasında kullanılmak üzere yeni bir veri kümesi sunulmaktadır. Öncelikle, çalışma kapsamında çeşitli derin mimari modelleri halkın kullanımına açık literatürde iyi bilinen hazır veri kümeleri ile test edilmiştir. Sonrasında, 25 - 55 yaş aralığındaki beş erkek ve beş kadından oluşan on gönüllü bireyin bel bölgesine yerleştirilen akıllı telefonla toplanan duyarga verileriyle oluşturulmuş yeni veri kümemiz kullanılarak çeşitli sınıflandırma deneyleri gerçekleştirilmiştir. Her bir aktivitenin iki farklı pozisyonda verisi alınmış, böylece 4 dinamik ve 3 statik aktivite içeren 15 saniyelik veriler elde edilmiştir. Her bir aktivite pozisyonu için 20 Hz örnekleme frekansıyla 1 saniyede sinyal penceresi başına 20 okuma yapılmaktadır. Çalışmadaki yazılımsal araç sayesinde tekrarlayan sinir ağı modelleri ve evrişimli sinir ağı modelini içeren derin öğrenme mimarilerinin farklı ağ parametreleri ve katman seçimine imkân sağlanarak çeşitli deneyler başarıyla gerçekleştirilmiştir. Yeni veri kümesi ham verilerin yanı sıra, Butterworth filtresi kullanımıyla oluşturulan bazı alternatif altkümeleri de içermektedir. Deneyler sonucunda, bireylerin çeşitli aktiviteleri için %97 ilâ %99 doğruluk oranında sınıflandırma başarımlı çeşitli veri kümeleriyle elde edilmiştir. Yeni veri kümesinin insan aktivitelerinin sınıflandırılması ve tahmin edilmesine dair çalışmalarda kullanıma uygunluğu kanıtlanmıştır.

A novel dataset of human daily activities: Its benchmarking results for classification performance via using deep learning techniques

H I G H L I G H T S

- A novel dataset consists of smartphone sensor data has been formed
- Performance evaluation and comparison was done through the use of deep learning architectural models
- For an objective performance benchmarking, a novel and unique software tool has been created

Article Info

Research Article
Received: 23.07.2020
Accepted: 15.10.2020

DOI:

10.17341/gazimmfd.772849

Keywords:

Human activities,
recurrent neural network,
convolutional neural
network,
dataset,
performance evaluation

ABSTRACT

Studies to classify human activities can contribute to the development of new systems that will facilitate daily life by evaluating the interaction of individuals with their environment. In this study, a novel data set is presented to be used in classifying the activities that individuals perform during the day. First of all, various deep architectural models presented in the study were tested with publicly available datasets well-known in the literature. Afterwards, various classification experiments were carried out by using our novel dataset, which was created with the sensor data collected with the smartphone located onto the belly region of ten volunteer individuals consisting of five males and five females aged between 25 and 55 years. Data of each activity at two different positions were taken, and also, 15 seconds raw data including 4 dynamic and 3 static activities were acquired. With 20 Hz sampling frequency for each activity position, 20 readings are made per signal window in 1 second. Thanks to the software tool developed for the study, various human activities were successfully classified in experiments by allowing different network parameters and layer selection for the deep learning architectures including recurrent neural network models and convolutional neural network model. The novel dataset contains raw data, as well as, it involves some alternative subsets created with the use of Butterworth filter. As a result of experiments, the classification performance at accuracy rate of 97% to 99% for various activities of individuals was obtained on various datasets. The suitability of using the novel data set in studies on classification and prediction of human activities has been proven.

1. GİRİŞ (INTRODUCTION)

Bireylerin uzuvlarından alınan hareket verileri sayesinde insan aktivitelerinin sınıflandırma çalışmaları gerçekleştirilmektedir. Gelişen teknoloji ile jiroskop, ivmeölçer duyargaları ve Global Pozisyon Sistemi (GPS) gibi akıllı telefonlar içerisinde hazır olarak gelen birçok duyarganın mevcut olması ve bu cihazlara uygun fiyatla kolaylıkla erişilebiliyor olması insanların farklı uzuvlarına böyle duyargaları yerleştirerek tespit edilen aktivitelerin sınıflandırma çalışmalarının gerçekleştirilmesini kolaylaştırmıştır [1]. İnsan aktivitelerinin sınıflandırılması; sağlık alanı, tıbbi ürünlerin geliştirilmesi, güvenlik sistemleri, ulaşım hizmetlerinin iyileştirilmesi ve akıllı ev sistemlerinin otomatikleştirilmesi gibi alanlarda sıklıkla kullanılmaktadır. Kullanım alanlarıyla alakalı literatürdeki çalışmalar incelendiğinde; yaşlı insanların bakımlarının kolaylaştırılması için ev ortamında yardımcı sistemler üzerine çalışmalar yapılmış ve bu çalışmalar kapsamında giyilebilir duyarga ağları geliştirilmiştir [2]. Makine öğrenmesi yöntemleri kullanılarak geliştirilen bir sistemde insanların aktiviteleri ile ev aletleri ilişkilendirilerek elektrik tüketiminde tasarruf edilmesi gerçekleştirilmiştir [3]. İnsanların toplu taşıma araçları üzerinde yanlış seçim yapmasını engellemek amaçlı gerçekleştirilen bir çalışmada ise ulaşım alanında insan aktivitelerinin sınıflandırılmasının katkısı görülmektedir [4]. Başka bir çalışmada ise ayakta durma, yürüme, uzanma ve koşma aktivitelerin sınıflandırılması üç eksenli ivmeölçer duyargasıyla elde edilen değerlerle yapılmıştır. Böylece %99 oranında başarıya yapılan testlerle ulaşılmıştır [5]. Literatürdeki diğer bir çalışmadaysa oturma, merdiven inme, yürüme, merdiven çıkma, tempolu yürüme ve ayakta durma aktiviteleri 29 gönüllüden toplanan duyarga verileri ile yapılan sınıflandırma sonucunda %91,7 test başarımlı doğruluğuna ulaşılmıştır [6]. Bir diğer çalışmada, insanların kronolojik sırada düzenlenerek birleştirilmiş eklem koordinatları dizininin matris olarak belirtilmesi gerçekleştirilmiştir. Bu matrislerin görüntü biçiminde Evrişimli Sinir Ağları (ESA) modeli üzerinde ele alınmasıyla aktivite sınıflandırması gerçekleştirilmiştir [7]. Uzun Kısa Süreli Bellek (UKSB) hücreleri ile insan aktivitelerinin sınıflandırılmasında %92,1 test başarımlı doğruluğunda bir sonuca, halkın kullanımına açık bir veri kümesi üzerinde yapılan bir çalışmada ulaşılmıştır [8].

Literatürde gerçekleştirilmiş çalışmalarda, insan aktivitelerinin sınıflandırılmasında farklı veri kümeleri ve teknikler de ele alınmıştır. Gerçekleştirilen çalışmaların büyük çoğunluğunda klasik Yapay Sinir Ağları (YSA) modelleri kullanılmıştır. YSA, farklılık gösteren aktivite özniteliklerini ve öznitelikler arasında var olan ilişkiyi zaman serileri üzerinden işleyememektedir. Bu bakımdan, gerçekleştirilen çalışmada insan aktivitelerinin sınıflandırılmasında güvenilir ve hızlı öğrenme için derin ağ mimarileri ile modeller oluşturulmuştur. Oluşturulan farklı derin öğrenme modelleri gerçek zamanlı insan aktivitelerinin sınıflandırılmasında kullanılabilir bir altyapıyı

sağlamakta, böylece çalışmamızda bu modeller nesnel olarak karşılaştırılabilmektedir. Yapılan çalışmada, insan günlük aktivitelerinin sınıflandırma görevi için ham ve filtrelenmiş sinyaller derlenerek duyarga verilerinden oluşan yeni bir veri kümesi oluşturulmuş ve alternatif alt kümeleri ile birlikte literatüre sunulmuştur. Başarım değerlendirme ve karşılaştırma, literatürdeki iki farklı veri kümesi ve önerilen yeni veri kümesi için insanların günlük aktivitelerinin sınıflandırılmasında derin öğrenme ağ mimari modellerinin kullanımı yoluyla yapılmıştır. Adil ve nesnel bir başarımlı kıyaslaması için, derin öğrenme mimarileri ile yapılan deneylerin farklı ağ parametreleri ve katman sayıları ile yapılabilmesini sağlayan esnek bir deney ortamına olanak sunan yazılımsal araç oluşturulmuştur.

Bu çalışmanın ana katkıları yeni veri kümesinin kullanılabilirliği ve önemini ortaya koyacak şekildedir. Buna göre; insan günlük aktivitelerinin sınıflandırma görevi için ham ve filtrelenmiş sinyaller derlenerek duyarga verilerinden oluşan yeni bir veri kümesi oluşturulmuş ve alternatif alt kümeleri ile birlikte literatüre sunulmuştur. Gerçekleştirilen çalışmada başarımlı değerlendirme ve karşılaştırma, literatürdeki iki farklı veri kümesi ve önerilen yeni veri kümesi için bireylerin günlük aktivitelerinin sınıflandırılmasında derin öğrenme mimari modellerinin kullanımı yoluyla yapılmıştır. Bu çalışmanın literatüre sunduğu en önemli katkılardan bir diğeri ise, adil ve nesnel bir başarımlı kıyaslaması için, derin öğrenme mimarileri ile yapılan deneylerin farklı ağ parametreleri ve katman sayıları ile yapılabilmesini sağlayan esnek bir deney ortamının sunuluyor oluşudur. Buna temel oluşturan ve alanında ilk kez bu kapsamda sunulmuş özgün bir yazılımsal araç oluşturulmuş olması bu katkıyı güçlendirmektedir.

Çalışmanın geri kalan bölümleri şu şekilde düzenlenmiştir. İkinci bölümdeki materyal ve metod kısmı ile insan aktivite tespiti, veri kümesi, Tekrarlayan Sinir Ağları (TSA) ve ESA'nın mimari yapısı detaylandırılmıştır. Üçüncü bölümde insan aktivitelerinin sınıflandırılmasında kullanılan derin öğrenme modelleri ve önerilen yazılımsal araç sunulmuştur. Dördüncü bölümde yapılan deneysel çalışmalara ve son bölümde ise elde edilen sonuçlar üzerine yapılan tartışmaya yer verilmiştir.

2. MATERYAL VE METOT (MATERIAL AND METHOD)

Bu bölümde insan aktivite tespitinden, çalışmada kullanılan duyarga çeşitlerinden, halkın kullanımına açık veri kümeleri ile çalışma kapsamında oluşturulan insan günlük aktiviteleri veri kümesi (İGAV) için veri edinimi (data acquisition) işleminin nasıl gerçekleştirildiğinden ve son olarak da ESA ve TSA modellerinin altyapısından detaylı olarak bahsedilmektedir.

2.1. İnsan aktivitelerinin tespiti (Human activities detection)

Gelişen teknolojiye dayanan çağ, insanların bilgisayarlar ile uyum içerisinde yaşamasını önemli ölçüde etkilemiştir. Bu

sebeple insan aktivitelerinin sınıflandırılma çalışmaları popüler araştırma konuları arasında yerini almıştır [9]. İnsanların uyum içerisinde oldukları çevre koşullarında gerçekleştirdikleri aktivitelerin tespit edilmesinde belirlenen hareket etiket olarak kabul edilerek veri toplama ve veri edinimi işlemleri gerçekleştirilmektedir. Elde edilen veriler daha sonra farklı şekillerde işlenerek aktivite sınıflandırma başarım oranının artırılması amaçlanmaktadır. İnsan aktivitelerini sınıflandırma çalışmaları, hastalıkların tedavi süreci, hareket analizleri, akıllı algılayıcı sistemlerinin geliştirilmesi ve otomatikleştirilmesi gibi alanların başlıca gelişim konusudur [10]. İnsanların günlük yaşantılarında gerçekleştirdikleri aktiviteler; basit (basic) ve karmaşık (complex) olarak iki kategoriye ayrılmaktadır. Basit aktivitelere; oturma, merdiven çıkma, merdiven inme, uzanma, yürüme gibi aktiviteler örnek verilebilir. Birden fazla aktivitenin birlikte gerçekleştirilmesiyle oluşan karmaşık aktivitelere; diş fırçalamak, araba kullanmak, evi temizlemek ve bisiklet kullanmak gibi aktiviteler olarak literatürdeki çalışmalarda da yer verilmektedir [11].

2.1.1. Akıllı telefon duyargaları ve veri edinimi (Smartphone sensors and data acquisition)

İnsan aktivitelerinin sınıflandırılmasına dair ilk çalışmalarda daha çok görüntü üzerinden elde edilen veriler ile işlemler yapılırken, günümüzde bu işlemler daha çok akıllı telefon ve giyilebilir duyargalardan elde edilen veriler ile gerçekleştirilmektedir [12]. Akıllı telefonlar içerisinde bulunan duyargalar kolay kullanımı, kolay ulaşılabilirliği ve düşük maliyetleri sebebi ile günümüz çalışmalarında tercih edilmektedir. Literatürde yer alan çalışmalarda daha çok akıllı telefonlar içerisinde yer alan ivmeölçer ve jiroskop duyargalarından elde edilen veriler ile sınıflandırma çalışmaları yapılmaktadır [13]. İvmeölçer duyargası, doğrusal ivme ve yerçekimi kuvveti verilerinin elde edilmesini sağlamaktadır. Birimi *metre/(saniye)²* olarak verilir. Veri edinimi, cihazın etki altında kaldığı ivme değerinin üç eksen boyunca ölçülmesiyle gerçekleştirilir. Jiroskop duyargası, yön tayini için üç eksen boyunca gerçekleştirilen dönme hareketinin açısal hızını ölçmekte kullanılır [14, 15]. Birimi *radyan/saniye*'dir.

İnsan aktivitelerinin sınıflandırılması çalışmalarında, işlemlerin hangi platform üzerinde hangi yöntem ile gerçekleştirileceği belirlenerek ham verilerin elde edilmesi aşamasına geçilmektedir. Literatürdeki çalışmalarda bu veri edinimi için kullanılan akıllı telefon ve giyilebilir duyargalarda en önemli seçim örnekleme frekansının belirlenmesidir [16]. İnsanlar üzerinden elde edilen ham duyarga verilerine, veri temizleme ve ön işlemler uygulandıktan sonra gerçekleştirilen sınıflandırma çalışmalarında daha yüksek doğrulukta sonuçlar elde edildiği görülmektedir [17]. Duyarga verilerinin ön işlemlere tabii tutularak düzenli hale getirilmesinde literatürdeki çalışmalarda farklı birçok yöntem kullanılmıştır. Bunların bazılarını baktığımızda; minimum, maksimum, medyan, z-skor hesaplaması, Butterworth alçak geçiren filtresi ve genişlik normalizasyonu kullanılmıştır [18]. Yukarıda

belirtilen; veri edinimi, ön işlemler ve veri temizleme aşamaları sonrasında eğitim işlemine geçilmektedir. Literatürde gerçekleştirilen çalışmalarda eğitim işlemi için farklı algoritmalar ile hazır platformlar kullanılmaktadır. Eğitimin gerçekleştirileceği model ya da modeller hazır platform üzerinde denenecekse bu platformun seçilmesi sonrasında katman sayısı, başlangıç parametreleri ve eğitim yineleme sayısının belirlenmesi gerçekleştirilmektedir [19]. Literatürde gerçekleştirilen bir çalışmada gün içerisindeki bireylerin yaptığı 15 farklı aktivitenin sınıflandırılmasında bu bireylerin göğüs bölgesine yerleştirilen üç eksenli ivmeölçerden elde edilmiş veriler kullanılmıştır. Bu sınıflandırma işlemi ile deneylerde %97,9 test başarım doğruluğu YSA kullanılmasıyla elde edilmiştir [20]. Bu bakış açısıyla aktivite sınıflandırma işlemi için iyi bir veri kümesine, uygun ön işlemlere ve uygun bir sınıflandırıcı modele ihtiyaç vardır. Literatürde gerçekleştirilen çalışmalarda sınıflandırma işlemi gerçekleştirilmek için eğitimler tamamlandıktan sonra ilgili aktivitelerin sınıflandırma başarımlarının sonuçları elde edilmektedir. Bu kapsamda en sık kullanılan ölçütler; başarım doğruluğu (accuracy), duyarlık (precision), anma (recall), F1 skoru ölçütleridir. Bunların yanı sıra literatürde AUC (Area Under Curve) olarak da bilinen Eğrinin Altında Kalan Alan (EAKA) değeri, ROC (Receiver Operating Characteristics) olarak literatürde ifade edilen Alıcı İşletim Karakteristik (AİK) eğrisi mevcuttur. Ayrıca gerçek sınıf etiketleri ile tahmin edilen sınıf etiketlerinin karşılaştırılmasında karmaşıklık matrisi (confusion matrix) kullanılmaktadır. Başarım ölçütleri hesaplanırken literatürde çoğunlukla kullanılan ölçüm terimleri; doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN)'dir [21]. Doğruluk değeri ile modelin başarımı doğru orantılıdır. Bu değer ne kadar büyürse modelin başarımı da o kadar artmaktadır. Bu ölçütün formülü Eş. 1'de verilmiştir [21].

$$\text{Doğruluk} = \frac{|DP|+|DN|}{|DP|+|DN|+|YP|+|YN|} \quad (1)$$

Duyarlık ölçütü, pozitif olarak tahmin edilen değerlerin gerçekteki pozitif miktarını belirtmektedir. Bu ölçütün formülü Eş. 2'de verilmiştir [21]. Anma ölçütü, pozitif sınıfta olması gereken değerlerin ne kadarının pozitif olarak sınıflandırıldığını ifade etmektedir. Bu ölçütün formülü Eş. 3'te verilmiştir [21].

$$\text{Duyarlık} = \frac{|DP|}{|DP|+|YP|} \quad (2)$$

$$\text{Anma} = \frac{|DN|}{|DN|+|YN|} \quad (3)$$

Anma ve duyarlık değerlerinin harmonik ortalaması F1 skorunu oluşturmaktadır. Eş. 4'de bu ölçütün formülü verilmiştir [21]. Eş. 4'te verilen F1 skoru değeri literatürdeki çalışmalarda hem ondalık sayı olarak hem de yüzdelik oran olarak ifade edilebilmektedir. Bu açıdan, Eş. 4'den elde edilecek F1 skoru değeri 100 ile çarpılarak yüzdelik orana dönüştürülebilmektedir. Çalışmamızda da yüzdelik oran olarak F1 skoru değerleri verilmektedir.

$$F1 \text{ skoru} = 2 * \frac{\text{Duyarlık} * \text{Anma}}{\text{Duyarlık} + \text{Anma}} \quad (4)$$

Sınıflandırma problemlerinde sınıflandırıcının başarımını analiz ederken EAKA değeri en güvenilir sonuca ulaşılması için önemli bir ölçüt olarak bilinmektedir. AİK eğrisinin altında kalan alan EAKA değerinin ölçümünde kullanılmaktadır. Farklı sınıflara dair olasılık eğrisi olarak AİK eğrisi oluşturulur [21].

$$\text{Doğru Pozitif Oranı} = \frac{|DP|}{|DP| + |YN|} \quad (5)$$

$$\text{Yanlış Pozitif Oranı} = \frac{|YP|}{|YP| + |DN|} \quad (6)$$

Bir AİK eğrisinde x ekseninde *yanlış pozitif oranı* (false positive rate) ve y ekseninde ise *doğru pozitif oranı* (true positive rate) bulunmaktadır. Hesaplamalara ait formüller Eş. 5 ve Eş. 6'da gösterilmektedir [21].

2.1.2. Halkın kullanımına açık veri kümeleri (Publicly available datasets)

İnsan aktivitelerinin sınıflandırılması için akıllı telefonlar ile çeşitli duyarga cihazları kullanılarak elde edilmiş çoğu veri kümeleri basit ve karmaşık aktivite verilerini içermektedir. Bu veri kümeleri; farklı örnekleme frekansları, çeşitli yaş aralığında ve farklı gönüllü kişi sayısı ile bireylerin farklı vücut bölgelerinden elde edilen veriler ile oluşturulmuştur. Bu bölümde, literatürdeki çalışmalarda yaygın olarak kullanılan insan aktivite tanıma (human activity recognition) UCI ve kablosuz sensör veri madenciliği (wireless sensor data mining) WISDM hazır veri kümelerinin detaylarına yer verilmiştir. Halkın kullanımına açık UCI veri kümesi, akıllı telefonun ivmeölçer ve jiroskop duyargaları ile 30 gönüllü bireyin bel bölgesinden elde edilen 6 farklı aktiviteye ait verilerinden oluşmaktadır [22]. Bu aktiviteler veri kümesinde; merdiven çıkma (walking upstairs), oturma (sitting), merdiven inme (walking downstairs), yürüme (walking), ayakta durma (standing) ve uzanma (laying) olarak verilmektedir. Önişlem sonrasında veri edinimi, duyarga sinyallerinden 50 Hz frekansla (2,56 saniyede bir örnekleme) gerçekleştirmiştir. Bu sayede, pencere başına saniyede 128 okuma sağlanmıştır. UCI insan aktivite tanıma veri kümesinde toplam 10299 adet veri bulunmaktadır. Bu verilerin %70'lik kısmı olan 7352 adeti eğitim aşamasında, geriye kalan %30'luk kısımdaki 2947 adet veri ise test aşamasında kullanılacak şekilde belirlenmiştir [23]. WISDM veri kümesi halkın kullanımına açık diğer bir veri kümesi olup, Fordham Üniversitesi (Amerika Birleşik Devletleri) tarafından üretilmiştir. Bu veri kümesinde 6 aktiviteye ait üç milyona yakın ham duyarga verileri bulunmaktadır. Bu veri kümesi içerisinde yer alan aktivitelere bakıldığında; tempolu yürüme (jogging), yürüme, merdiven çıkma, oturma, merdiven inme, ayakta durma aktiviteleri olduğu

görülmektedir [6]. Yalnızca üç eksenli ivmeölçer duyarga verilerini içeriyor olması farklı olarak üç eksenli jiroskop verilerini de barındıran UCI veri kümesi ile aralarındaki farkı göstermektedir. Önişlem sonrasında veri edinimi duyarga sinyallerinden 20 Hz frekanslı (50 milisaniyede bir örnekleme) olarak gerçekleştirmiştir. Böylece, pencere başına saniyede 20 okuma sağlanmıştır [24].

2.2. Yeni veri kümesi oluşturma (Construction of novel dataset)

Bu çalışmada, Python [25] programlama dili versiyon 3.7 kullanılarak derin öğrenme için yazılımın alt yapısı oluşturulmuştur. Derin öğrenme kütüphanesi olarak Tensorflow 1.14 [26] versiyonu tercih edilmiştir. Ayrıca, uygulama programlama arayüzü olarak Keras 2.2.4 [27] versiyonu kullanılmıştır. Grafik kullanıcı arayüzü kütüphanesi olarak Tkinter 8.6.8 [28] versiyonu tercih edilmiştir. Bu çalışmada 15 saniyelik bir veri edinimi işlemi; Apple firması tarafından geliştirilen IOS ve OS X platformu için Swift programlama dilinde [29] yazılmış açık kaynak kodlu yazılım [30] kullanılarak duyarga sinyallerinden 20 Hz frekansla (1 saniyede bir örnekleme) oluşturulan kayıtlar alınmıştır. Gönüllü kişilerin bel bölgelerine yerleştirilen akıllı telefon sayesinde veri kümesine ham veri oluşturmak adına üç eksenli jiroskop ve üç eksenli ivmeölçer duyargalarından alınan verilerin gerçek zamanlı olarak kaydedilmesi sağlanmıştır. Deneye katılan gönüllülerden duyarga verilerinin toplanmasında ise Apple firmasının iPhone 6 Plus akıllı telefon kullanılmıştır. Çalışmamızda oluşturulan insan günlük aktiviteleri veri kümesi (İGAV) için elde edilen öznelik tiplerini (İvmeX, İvmeY, İvmeZ, JiroskopX, JiroskopY, JiroskopZ) içeren veri formatı Şekil 1'de görülmektedir.

İGAV veri kümesi deneylerde kullanılmış olan haliyle çeşitli alt veri kümelerini içermektedir. Buna göre; ham haldeki İGAV veri kümesi 7 farklı tipteki insan aktivitesine ait duyarga verilerini içermektedir. Veri kümesi içerisindeki aktiviteler; oturma, yürüme, merdiven inme, zıplama, merdiven çıkma, ayakta durma ve uzanma olarak etiketlenmiştir. İGAV kümesinde veri edinimi, her bir aktivitenin belirlenen iki farklı pozisyonda verisi toplanması koşuluyla akıllı telefonunun jiroskop ve ivmeölçer duyargalarıyla; 4 dinamik aktivitenin (merdiven inme, zıplama, yürüme, merdiven çıkma) ve 3 statik aktivitenin (uzanma, oturma, ayakta durma) her biri için bağımsız olarak 15 saniyelik sürede gerçekleştirilmiştir [31]. Bu aktiviteler, farklı ortam koşullarında (iç veya dış mekân) 10 gönüllü bireyden gerçek zamanlı toplanmıştır. Her bir aktivite pozisyonu için 20 Hz örnekleme frekansı ile 1 saniyede bir örnekleme yoluyla veriler toplanarak akıllı telefonda depolanmış ve diğer pozisyona geçilmiştir. Saniyede pencere başına 20 okuma gerçekleştirilmiştir. Tablo 1'de 10 gönüllü birey için kaydedilen İGAV ham verileri kullanılarak elde edilen özneliklerin her bir aktiviteye dair ortalama ve standart hata değerleri görülmektedir. Deneydeki değerler

Gönüllü No	Aktivite	Zaman adımı	İvmeX	İvmeY	İvmeZ	JiroskopX	JiroskopY	JiroskopZ
------------	----------	-------------	-------	-------	-------	-----------	-----------	-----------

Şekil 1. İGAV veri formatı (IGAV data format)

sabit aralıkta (15 saniye) her bir bireyden alınan her bir aktiviteye 300 okuma değeri düşecek şekilde gruplandırılmış olarak veri kümesine alınmaktadır. Aynı aktiviteye dair farklı bireylerde yapılan kayıtlarda değer kümesi aralığında homojen bir dağılımın oluşmasına dikkat edilmiştir. Tüm veri kümesi incelendiğinde aktivite sınıflarının her birinin veri kümesi içerisinde eşit ağırlıklı bir biçimde (%14,28) yer aldığı görülmektedir.

Gönüllü 10 bireyin her birinden her bir aktivite başına 300 ham değer veri kümesine alınarak, 10 bireyden 3000 ham veri elde edilmiştir. Çalışmamızda 7 aktivite olması nedeniyle toplamda 21000 ham değer veri kümesine dahil edilmiştir. Duyargaları okumada sinyal kaydına girilirken kayıt tuşuna basma esnasındaki veya deneye katılmaması gereken diğer çevresel gürültüler sinyalden temizlenerek sadece aktivitelerin tam olarak kapsadığı alan sinyal penceresi olarak işleme alınmıştır. Tablo 2'de ham veya önışlemeden geçmiş halleriyle literatürdeki çokça kullanılan veri kümeleri ile çalışmamızdaki İGAV veri kümesi nitelikleri bakımından karşılaştırılmaktadır.

Çalışmamızdaki deneylerde, İGAV veri kümesinin ham hali ve Butterworth filtresi uygulanmasıyla oluşturulmuş farklı özneliklere sahip alt kümeleri kullanılarak testler gerçekleştirilmiştir. Ham verilere 0,3 Hz kesme frekansında Butterworth alçak geçiren filtresi uygulanarak verilerin düzenli hale getirilmesini sağlanmıştır [31]. İGAV kümesi oluşturulmadan önce, bilgilendirilmiş onam formu

(informed consent) farklı kilo ve boy oranlarında olan 25-55 yaş aralığından seçilen 5 kadın ve 5 erkek olmak üzere toplamda 10 gönüllüye sunulur; çalışmaya dair amaç ve detay bilgiler kendilerine açıklanmıştır. Buna dair etik kurul izni, Çanakkale Onsekiz Mart Üniversitesi'nin ilgili Fen Bilimleri Enstitüsü Etik Kurulu tarafından 12/11/2019 tarihli 2019/04 toplantısının 02 sıra no'lu kararı ile alınmıştır. Bu belgeye ve bilgilendirilmiş onam formuna ilgili yüksek lisans tezinden ulaşılabilmektedir [31].

2.3. Tekrarlayan sinir ağları (Recurrent neural network)

TSA, zaman serilerini kullanarak işlemleri gerçekleştiren bir YSA türüdür. İleri beslemeli ağların çalışma mantığından farklı olarak ağına girdi verileri TSA eğitimlerinde kullanılabilir. Geri yayılım (backpropagation) ise YSA'lara benzer olarak gerçekleştirilebilir. TSA ağları, aynı yapıya sahip TSA hücrelerinin birbirinden farklı gizli durumlarını işleyen kopyalarının bir araya gelmesi ile oluşmaktadır. Bu kopyalar TSA hücrelerinin gizli olmasına neden olmaktadır. Bu derin mimari modelinin tekrarlayan olarak isimlendirilmesinin sebebi çıktı verilerinin tekrardan girdi verisi olarak kullanılmasıdır [31, 32]. Şekil 2'de TSA'nın genel yapısı gösterilmektedir [33].

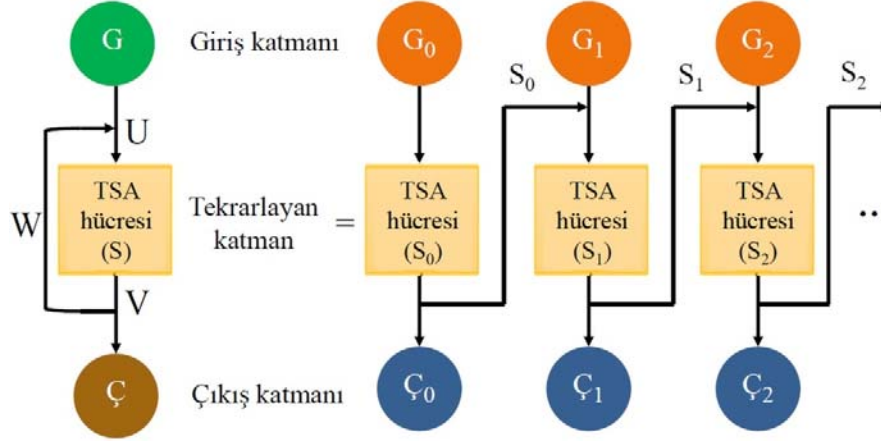
Burada, S_t değeri ile TSA hücrelerinin t anındaki gizli durumları ifade edilmektedir. Bu yöntem yardımı ile o anki adıma kadar ağa giren tüm girdi verileri üzerinden buradaki t anında işleme alınan G_t durumundaki girdi verisi

Tablo 1. İGAV kümesi ham verileri özneliklerinin farklı insan aktiviteleri için ortalama ve standart hata değerleri (Mean and standard error values for attributes of various human activities from IGAV dataset's raw data)

Aktivite İsmi		JiroskopX	JiroskopY	JiroskopZ	İvmeX	İvmeY	İvmeZ
Merdiven İnme	Ort. ve	0,1947	0,0044	0,0284	-0,1918	0,1460	-0,1117
	std. hata:	±0,0116	±0,0089	±0,0063	±0,0186	±0,0044	±0,0036
Zıplama	Ort. ve	0,0293	0,0038	0,0025	0,0098	0,2327	-0,0877
	std. hata:	±0,0125	±0,0175	±0,0147	±0,0296	±0,0065	±0,0070
Uzanma	Ort. ve	0,0247	0,0169	0,0068	0,0612	-0,3014	-0,6714
	std. hata:	±0,0005	±0,0006	±0,0003	±0,0028	±0,0111	±0,0032
Oturma	Ort. ve	0,0262	0,0190	0,0046	0,0064	-0,2878	-0,4602
	std. hata:	±0,0005	±0,0009	±0,0005	±0,0146	±0,0025	±0,0023
Ayakta Durma	Ort. ve	0,0256	0,0141	0,0072	-0,0007	0,1613	-0,1489
	std. hata:	±0,0010	±0,0007	±0,0004	±0,0176	±0,0014	±0,0024
Merdiven Çıkma	Ort. ve	-0,1603	0,0534	0,0067	-0,1929	0,2332	-0,0464
	std. hata:	±0,0107	±0,0121	±0,0061	±0,0176	±0,0032	±0,0038
Yürüme	Ort. ve	0,0921	-0,0040	0,0267	0,1905	0,2149	-0,0899
	std. hata:	±0,0152	±0,0097	±0,0071	±0,0177	±0,0039	±0,0035

Tablo 2. Veri kümelerini karşılaştırma (Comparison of datasets)

Nitelikler	UCI	WISDM	İGAV
Bakılan Aktivite	Kısa Süreli	Kısa Süreli	Kısa Süreli
Duyarga Tipi	İvmeölçer, Jiroskop	İvmeölçer	İvmeölçer, Jiroskop
Akıllı Telefon Yönelim ve Pozisyonu	Sabit	Sabit	Sabit
Birey Sayısı	30	29	10
Frekans (Hz)	50	20	20
Saniyede pencere başına okuma	128	20	20
Öznelik Sayısı	561 (İşlenmiş)	6 (Ham)	6 (Ham) + 6 (Butterworth)
Sınıf Sayısı	6	6	7



Şekil 2. TSA yapısı (Structure of RNN)

hesaplanmaktadır. Ayrıca, $(t - 1)$ anındaki mevcut gizli durum ise S_{t-1} değeriyle ifade edilmektedir. Eş. 7'de görülebileceği gibi uygun model oluşturularak buna ait U ve W ağırlık parametreleri kullanılmasıyla S_t değeri hesaplanmaktadır. Bu eşitlikteki f_A aktivasyon fonksiyonunu ifade etmektedir. Genellikle burada hiperbolik tanjant (\tanh) aktivasyon fonksiyonu seçilerek $[-1, 1]$ aralığında sonuç üretmektedir [34].

$$S_t = f_A(UG_t + WS_{t-1}) \quad (7)$$

Belirtilen hesaplamada normalize işlemi gerçekleştirilmiş softmax fonksiyonu kullanılarak $[0, 1]$ değerleri arasında ağırlık çıktısı (\hat{C}_t) elde edilmektedir. Belirtilen durumu Eş. 8'de görülmektedir.

$$\hat{C}_t = \text{softmax}(V * S_t) \quad (8)$$

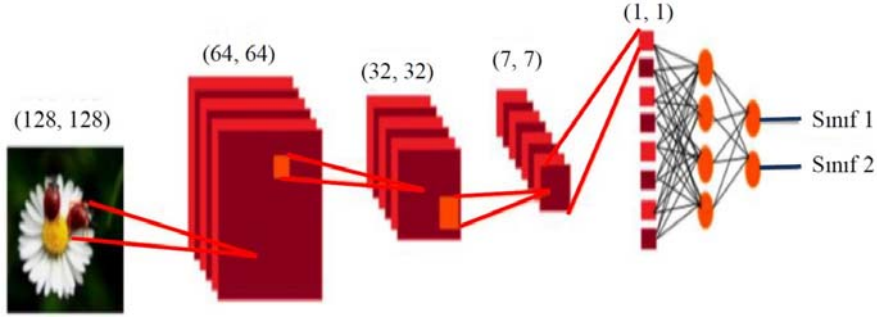
YSA'da girdi verileri tüm katmanlarda kullanıldığından gradyan değeri önceki katmanlara bağımlı biçimde değişmektedir. Geri yayılımın sürekli yenilenmesi sonrasında, hesaplamalardaki değerlerde azalma yaşanması sonucu kaybolan gradyan (vanishing gradient) problemi oluşabilmekte, buna benzer diğer bir durumdaysa 1'den büyük değer alan gradyanlar hesaplanan sonucun büyümesine yol açmaktadırlar. Bu durumda da patlayan gradyan (exploiting gradient) problemi ortaya çıkmaktadır. Oluşan bu problemlerin en aza indirilmesi için, uzun süreli bağımlılıkları da öğrenebilen yapıdaki TSA mimarisinin özel bir tipi olan UKSB hücreleri kullanılmaktadır. Uzun vadeli bağımlılık ve kaybolan gradyan gibi problemlere çözüm için geliştirilmiş olan ve TSA mimarisi göz önüne alındığında daha hızlı ve görece daha basit yapıda olan Kapılı Tekrarlayan Birim (KTB) modelleri de literatürde mevcuttur. Bu mimari bakış açısıyla, unutma kapısı (forget gate), girdi kapısı (input gate) ve çıktı kapıları (output gate) UKSB hücrelerinde bulunmaktadır [34]. KTB hücreleri reset kapısı ve güncelleme kapısı (update gate) içermekte, böylece UKSB hücrelerine göre hafızada bir verinin ne kadar uzun süre tutulup, güncel veri ile hafızadaki verinin hangi zaman adımında birleştirileceği gibi olgular belirlenebilmektedir [34]. Veri dizileri içerisinde belirli bir önceki $(t - 1)$ ve buna

ilişkin sonraki $(t + 1)$ zaman adımlarını işleyebilen çift yönlü işlevsel yapılar da literatürdeki çeşitli çalışmalarda mevcuttur. Çift yönlü işlevsel bir yapıya sahip olarak oluşturulan KTB ve UKSB hücrelerini içeren çeşitli modellerin aynı zamanda ardışık verileri işlemede bazı avantajları da vardır [35].

2.4. Evrişimli sinir ağları (Convolutional neural network)

ESA, görme duyusunun işlevinden faydalanan, görüntüleri alt bölümlere parçalayarak bütün görüntü üzerinde işlem yapan Çok Katmanlı Algılayıcı (ÇKA) türüdür. 1988 yılında Yann LeCun'ın öne sürdüğü ve 1998 yılına kadar da üzerinde iyileştirmelerin gerçekleştirildiği ilk ESA ağlarından birisi de LeNet ağıdır [36]. LeNet ağında; ÇKA yapısına benzeyen tam bağlı katman (fully connected layer), biriktirme katmanı (pooling layer) ve evrişim katmanı (convolution layer) yer almaktadır [37]. ESA, veriyi işlerken çeşitli filtreler kullanmakta, bu filtrelerin içerikleri veriden elde edilen öznitelikler olarak otomatik bir biçimde ağ tarafından öğrenilebilmektedir. Şekil 3'te ESA ağının iki boyutlu (2B) yapıda oluşturulan modeline dair altyapı şematik olarak görülmektedir [38].

ESA modellerinin katmanları incelendiğinde; evrişim katmanı ESA'nın temelini oluşturan dönüşüm katmanıdır. Bu katmanda, belirli ölçeklerdeki filtreler görüntüler üzerinde kaydırılarak öznitelik haritasının (feature map) oluşturulması sağlanır. Biriktirme katmanı; evrişim katmanları arasına eklenen katmandır. Model içerisinde parametre değerlerinin hesaplama miktarını azaltarak aşırı öğrenme (overfitting) nedeniyle ağ'da oluşan ezberlemeyi önler. Bu sayede ağ üzerinde uyumsuz durumların da engellenmesi sağlanmış olur. Düzleştirilmiş (flatten) veriler, tam bağlı katmanda alınarak sinir ağı vasıtasıyla öğrenme işlemi gerçekleştirilmektedir. İşlemler sonrasında belirlenen sınıflara göre dönüşümler gerçekleştirilmektedir. Bazı katmanlardaki sinir düğümlerinin eğitim süresi içerisinde pasif bir duruma getirilmesi ise iletim sönümü (dropout) katmanında gerçekleştirilir. Sadece ve sadece eğitim süresi içerisinde iletim sönümü gerçekleştirilmekte, tüm sinir düğümleriyse test işlemi süresince aktif durumda olmaktadır.



Şekil 3. ESA şematik yapısı (Schematic for structure of CNN)

Böylece iletim sönümü kullanımıyla; çok fazla ayrıntıya ağ modelinin odaklanması da engellenerek başarımlar iyileştirilmektedir. Her bir döngü süresince belirli bir oranda farklı sinir düğümleri böylece pasif hale getirilmekte ve aktif haldeki sinir düğümleriyse sürekli değiştirilmektedir [37]. Ara katmanların doğrusal olmayan biçimde veriyi işlemede aktivasyon fonksiyonu olarak doğrultulmuş biçimli doğrusal birim olarak bilinen ReLU (Rectified Linear Unit) içeren bir yapı sıklıkla literatürdeki çalışmalarda kullanılmaktadır [39]. Bu fonksiyon sayesinde öznitelikler üzerinde belirli bir filtreleme de yapılmaktadır.

3. İNSAN GÜNLÜK AKTİVİTELERİNİN DERİN ÖĞRENME MODELLERİ KULLANILARAK SINIFLANDIRILMASI

(CLASSIFICATION OF HUMAN DAILY ACTIVITIES USING DEEP LEARNING MODELS)

Bu bölümde, derin ağ mimari modellerin ilgili ağ katman yapısı ve parametrelerle ilgili aktivite sınıflandırma deneylerinde kullanmak üzere nasıl oluşturulduklarına dair detaylar belirtilmiştir.

3.1. Derin öğrenme modellerini oluşturma (Construction of deep learning models)

İnsan aktivitelerinin sınıflandırılması için oluşturulan herhangi bir TSA tipi ile oluşturulabilen ağ modeli şablonunun ayrıntıları Tablo 3'te gösterilmiştir. Sadece ilgili modellerin ağ parametreleri birbirlerinden farklıdır. Diğer TSA modelleri için de Tablo 3'te verilen ağ model katman düzenleme yapısının aynısı çalışmamızda kullanılmıştır. Tablo 3'te hangi TSA tipine uygun ağ modeli tercih edilecekse ona uygun aynı tipteki 3 adet katmanla ağ modeli düzenlemesi oluşturulur. Örneğin, TSA_tip# için UKSB seçilmişse 3 tane UKSB katmanı ardışık sırada ağ modeline eklenmiştir (UKSB_1, UKSB_2 ve UKSB_3). Tablo 3'ün açıklamasında da bu durum görülmektedir. Tablo 3'te örnek olarak UKSB tipi katmanlarla kurulmuş bir ağ modeli için son sütunda parametre sayıları gösterilmiştir. Oluşturulan modelden yola çıkılarak; 7 adet sınıflandırılacak olan aktivitenin, her bir ilgili ağ modelinde de seçilen TSA tipinde 3 katmanı içerecek şekilde olması koşuluyla; Uzun Kısa Süreli Bellek (UKSB), Kapılı Tekrarlayan Birim (KTB), Çift yönlü UKSB veya Çift yönlü KTB modelleriyle deneylerde sınıflandırmalar gerçekleştirilmiştir. Modellerin ilk

katmanlarında 128 düğüm bulunmaktadır. Aynı zamanda katmana uygulanan filtre büyüklüğünü belirtmektedir. Daha sonraki katmanlarda düğüm sayısı; 64 ve 32 olarak belirtilmiştir. Burada, çalışmamızdaki aktivite türlerinin mevcut sınıf sayısına uygun biçimde sonuç üretecek olan tam bağlantılı katman olması nedeniyle *softmax* aktivasyon fonksiyonu uygulanan son katmana Yoğun (dense) denilmektedir. Böylece 7 farklı tipteki aktivite sınıfına dair sınıflandırma yapılmaktadır. Burada, 20 Hz frekansla saniyede bir örnekleme yapılmış bir biçimde zaman bölütü değeri ağ katmanlarında kullanılmıştır.

Tablo 3. İGAV kümesi için oluşturulmuş TSA tipli ağ modeli şablonu

(Template model for RNN-type networks for IGAV dataset)

Katmanlar	Çıktı Birim Biçimi	Parametreler*
TSA_tip# Katman_1	(Yok, 20, 128)	67584
TSA_tip# Katman_2	(Yok, 20, 64)	49408
TSA_tip# Katman_3	(Yok, 32)	12416
İletim Sönümü	(Yok, 32)	0
Yoğun	(Yok, 7)	231

TSA_tip#: UKSB, KTB veya çift yönlü işlevsel yapı.

*Toplam parametreler: 129,639

Tablo 4'de ise deneylerde kullanılmak üzere oluşturulan 1 Boyutlu (1B) yapıdaki ESA modelinin ayrıntıları belirtilmiştir. Tablodaki ayrıntılar incelendiğinde görülebileceği gibi; evrişim katmanı tarafından oluşturulan öznitelik haritasının, kendisi de bir ara katman olan *azami biriktirme* (maximum pooling) katmanına geçirilerek belirli bir boyut indirilmesi gerçekleştirilmektedir. Böylece bir sonraki evrişim katmanına bu öznitelik haritası bir miktar indirilerek geçirilmiş olur.

Tablo 4'deki modelden de görüldüğü üzere, filtre büyüklüğüne uygun olarak birinci evrişim katmanında düğüm sayısı 128 olarak ayarlanmıştır. Ara katmanlarda her bir katmanın aktivasyon işleminde ReLU fonksiyonu kullanılmaktadır. Filtre uygulanmasıyla düğüm sayısı üçüncü evrişim katmanında 64 olmuştur. İkinci azami biriktirme katmanı kullanılmasıyla öznitelik haritasının boyutu indirilmiş ve düğüm sayısı 32 olmuştur. Buradaki, *genel ortalama biriktirme* (global average pooling) işlemi ile azami biriktirmenin aksine en büyük değeri almak yerine verilen penceredeki değerlerin ortalaması alınır. Bu sayede istenilen boyut indirgeme daha genel bir bakış açısıyla

Tablo 4. İGAV kümesi için oluşturulmuş 1B ESA ağ modeli (1D CNN network model for IGAV dataset)

Katmanlar	Çıktı Birim Biçimi	Parametreler*
1Boyutlu_EvrişimKatman_1	(Yok, 19, 128)	1664
1Boyutlu_EvrişimKatman_2	(Yok, 18, 128)	32896
1Boyutlu_AzamiBiriktirme_1	(Yok, 9, 128)	0
1Boyutlu_EvrişimKatman_3	(Yok, 8, 64)	16448
1Boyutlu_EvrişimKatman_4	(Yok, 7, 64)	8256
1Boyutlu_AzamiBiriktirme_2	(Yok, 3, 64)	0
1Boyutlu_EvrişimKatman_5	(Yok, 2, 32)	4128
1Boyutlu_GenelOrtalamaBiriktirme_1	(Yok, 32)	0
İletim Sönümü	(Yok, 32)	0
Yoğun	(Yok, 7)	231

*Toplam parametreler: 63,623

yapılmış olur. Çalışmamızda Tablo 4'dekine benzer yapıda 1 Boyutlu (1B) ESA ağ modeli kullanılarak UCI veri kümesi ile yapılan tüm deneylerde bu modelin ayarlanan filtresine uygun olacak şekilde evrişim katmanlarındaki çekirdek (kernel) büyüklüğü 5 olarak belirlenmiştir. Ayrıca, çalışmamızda WISDM veri kümesinin kullanıldığı bu ağ modeliyle yapılan tüm deneylerde evrişim katmanlarındaki çekirdek büyüklüğü 10 olarak alınmıştır. Bunun yanı sıra, UCI ve WISDM veri kümeleri için bu ağ modelinde 1 Boyutlu azami biriktirme miktarı 3 olarak seçilmiştir. Tablo 4'de verilen 1B ESA ağ modeli, çalışmamızdaki İGAV ham veri kümesi ve buna ait veri alt kümeleri ile yapılan tüm deneylerde kullanılmıştır. Tablo 4'deki ağ modelinin ayarlanan filtresine uygun olacak şekilde evrişim katmanlarındaki çekirdek büyüklüğü 2 olarak ve azami biriktirme miktarı ise 2 olacak şekilde belirlenerek İGAV ham veri kümesi ve alt veri kümelerinin tüm deneyleri için kullanılmıştır. Böylece Tablo 4'deki 1B ESA ağ modelinin WISDM, UCI veya İGAV veri kümeleri için pratik uygulamadaki farklı yanı sıra sadece ilgili veri kümesi için belirlenen çekirdek büyüklüğü ve azami biriktirme miktarı olmaktadır. TSA model altyapısında da olduğu gibi buradaki Yoğun isimli katmandaki birimler de tam bağlantılı birimlerdir. Böylece düzleştirilmiş verilerle derin ağ modeli insanın yedi farklı tipteki günlük hareketinin sınıflandırılmasını gerçekleştirmektedir. Hem 1 Boyutlu ESA hem de TSA tipindeki ağ modelleri için çalışmamızdaki ağ modellerinin eğitiminde amaç fonksiyonu (objective function) şeklinde nitelendirebileceğimiz kayıp fonksiyonu (loss function) olarak kategorik çapraz entropi (categorical cross-entropy) fonksiyonu [39] ve eniyileme için ADAM uyarlanırlar momentler (adaptive moments estimation) yöntemi kullanılmıştır. ADAM eniyileme yöntemi, gradyanların birinci ve ikinci momentlerinin hesabına dayanarak sinir ağı eğitimi için uyarlanırlar bir öğrenme oranı (learning rate) oluşturulmasında hesapsal olarak etkin olan ve bellek isterleri oldukça az bir stokastik eğimli iniş (gradient descent) yöntemidir [40].

Hem TSA ağ modelleri (UKSB, KTB ve bunların çift yönlü halleri) hem de 1 Boyutlu (1B) ESA modeli için iletim sönümü (dropout) %20 oranında belirlenerek deneylerde ilgili katmanlar için kullanılmıştır. Deneylerimizdeki TSA modellerinin tümü ve 1B ESA modeli için erken durdurma işlemi eğitim esnasında uygulanırken modelin eğitiminin

geçerilemesinde (validation) kullanılmak üzere deneydeki ilgili veri kümesinden alınan belirli bir kısmın üzerinden geçerileme kayıp fonksiyonu (validation loss function) değerinin takip edilmesi yolu tercih edilmiştir. Buna göre eğer eğitim esnasında izlenen geçerileme kayıp fonksiyonunda en azından minimum delta miktarı kadar (0,0001) bir değişim gerçekleşmiyorsa eğitimde olumlu yönde gelişme yaşanmadığına otomatik olarak karar verilerek eğitim durdurulmaktadır. Çalışmamızda bahsi geçen derin öğrenme modellerin eğitimleri sırasında deneysel sonuçlardaki iyileşmenin takip edilerek erken durdurma yapılmasında Keras uygulama programlama arayüzü üzerindeki "EarlyStopping" ve "ReduceLronPlateau" fonksiyonları kullanılmıştır [27]. Buna göre; minimum öğrenme oranı (learning rate) alt sınırı $5 \cdot 10^{-7}$ olacak şekilde öğrenme oranı ilgili adımlarda öğrenme oranının 0,3162 katı kadar küçültülerek erken durdurma için gerekli ağ parametreleri takip edilmiştir. Tüm deneylerde ADAM eniyileme yönteminin [40] uygulanmasında Keras ile gelen mevcut "optimizer" fonksiyonunun "Adam" sınıfı kullanılmıştır [27]. Tüm deneylerin başlangıcında Keras ile gelen bu fonksiyon tarafından kullanılan parametrelerin ilk değerleri olarak; öğrenme oranı α için 0,001, üstel azalma oranları olarak birinci momentin hesaplanılmasına dair β_1 için 0,9 ve ikinci momentin hesaplanılmasına dair β_2 için 0,999 değeri belirlenmiş, nümerik kararlılığın oluşmasında kullanılan küçük bir sabit olan ϵ için $1 \cdot 10^{-7}$ değeri belirlenerek tüm deneylerdeki tüm modeller için kullanılmıştır. Bu parametrelerin matematiksel altyapılarının detaylarına ve ADAM eniyileme yöntemine dair algoritmaya Kingma ve Ba'nın çalışmasında [40] yer verilmektedir.

3.2. Önerilen yazılımsal araç (Proposed software tool)

Çalışma kapsamında tasarlanan yazılımsal araç, insan aktivitelerinin sınıflandırılması çalışmasında kullanıcının farklı parametre ve derin öğrenme mimarileri kullanarak çeşitli deneyler gerçekleştirmesini sağlamaktadır. Bu imkân bir komut satırı uçbirimi (konsol) ya da tümleşik geliştirme ortamı üzerinde düzenleme yapmaya gerek kalmadan kolaylıkla deneylerin gerçekleştirilmesine olanak sağlamaktadır. Şekil 4'de çalışmamızda tasarlanan bu yazılımsal aracın ekran görüntüsü görülmektedir. Aynı zamanda aşağıda programın özellikleri ve seçim imkânı

Şekil 4. Çalışmadaki yazılımsal aracın grafik kullanıcı arayüzü (Graphical user interface of software tool in the study)

sağladığı parametrelerin açıklamaları verilmiştir. Geliştirilen program kullanıcıya; KTB, UKSB, Çift yönlü KTB, Çift yönlü UKSB ve 1 Boyutlu ESA derin ağ mimari modellerinden seçim yapma imkânı sunmaktadır. Veri kümesi seçimi özelliği ile deneylerin gerçekleştirilmesi için WISDM, UCI veya İGAV veri kümelerinden hangisinin kullanılmasına seçilen derin ağ mimari modelinin test edileceğine kullanıcının karar vermesi sağlanmaktadır. Şekil 5'de (a) İGAV veri kümesinin ham haldeki ivmeölçer duyarga verileriyle oluşturulan alt veri kümesinin öznitelikleri ve (b) örnek ekran çıktısı butonunun dökümü görülmektedir.

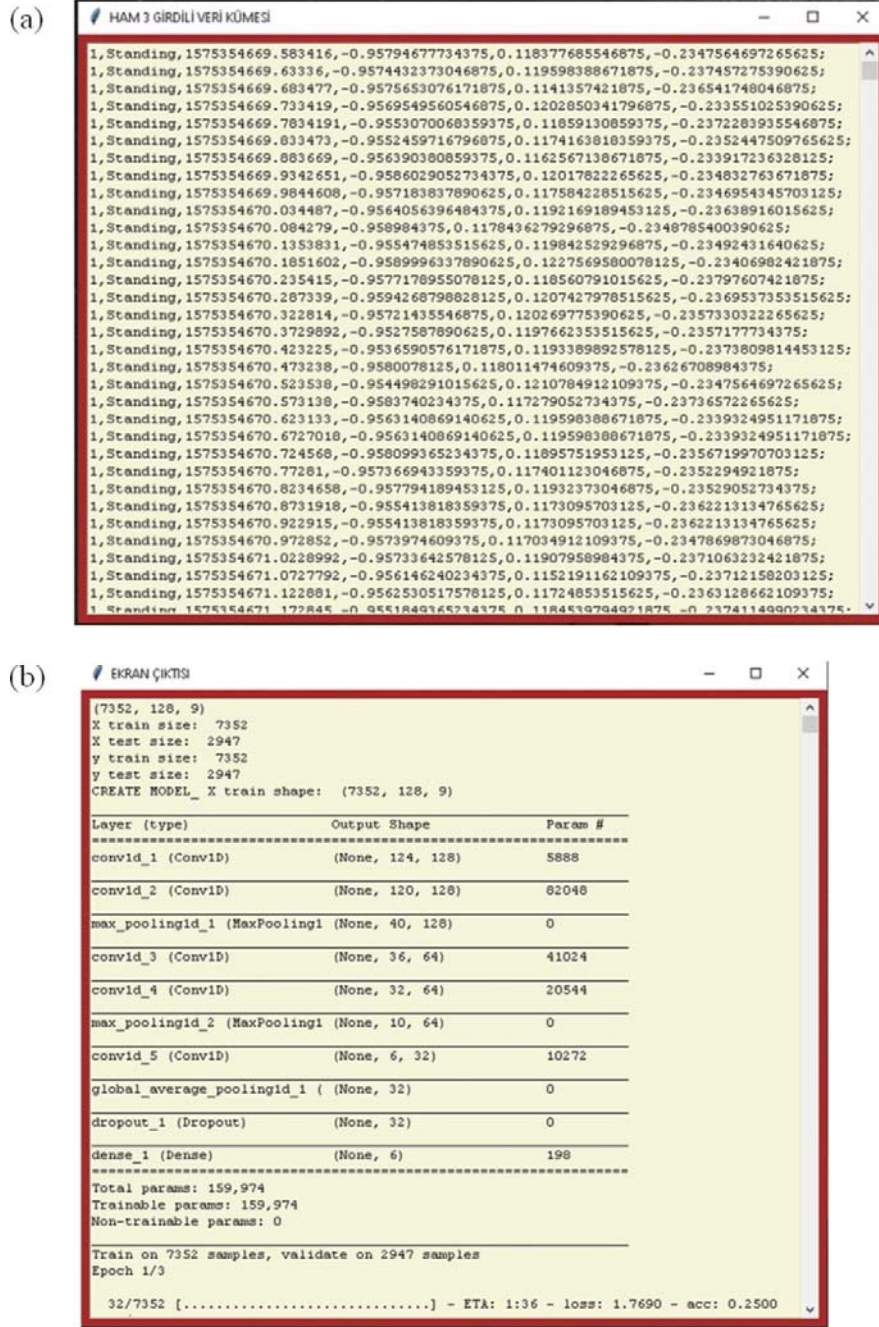
Veri kümesi göster butonu, seçilen veri kümesine ait özniteliklerin gösterilmesini, ekran çıktısı butonuysa eğitimi gerçekleştirilen modelin konsol çıktılarını sağlamaktadır. Tasarlanan yazılımdaki eğitim yineleme sayısı (*epoch*) özelliği ise eğitimi gerçekleştirilecek modelin kaç adımda eğitileceğini belirlemektedir. Eğitim devam ederken aşırı öğrenme gibi problemlerin yaşanmaması için eğitim esnasındaki çeşitli değerleri takip edecek bir yapı sayesinde erken durdurma (*early stopping*) yapılabilmesi imkânı yazılım aracılığıyla kullanıcıya sunulmaktadır. Bu özellik de tasarlanan yazılımın grafik kullanıcı arayüzünde mevcuttur. Katman sayısı ile modelin kaç katman üzerinden işlemlerini gerçekleştireceği belirtilmektedir. Düğüm sayısı ise belirtilen her bir katmanda kaç adet sinir düğümü olacağını ifade etmektedir.

Burada; veri kümesinin kullanıcı tarafından belirlenen parçalar halinde işlenmesinde kullanılan parametre, parçalanma boyutu (*batch size*) olarak belirtmektedir.

Ayrıca; zaman bölütü (*time segment*) sayesinde dizi işlemede birim saniyede gerçekleştirilen örnekleme oranı kullanıcı tarafından belirlenebilmektedir. Yazılımsal araç ve alt kümeleri ile birlikte İGAV veri kümesi ilgili İnternet sitesinde araştırmacıların kullanımına açılmıştır [41].

4. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Çalışma kapsamında, duyarga verileri kullanılarak insan aktivitelerinin sınıflandırılması gerçekleştirilmiştir. UCI, WISDM ve çalışmamız kapsamında oluşturulan İGAV veri kümeleri üzerinde KTB, UKSB, Çift yönlü KTB, Çift yönlü UKSB ve 1 Boyutlu ESA modelleri ile denenmiştir. Bu bölümde modellerin başarımlarını oranları detaylıca verilmektedir. UCI veri kümesi için çalışmamızdaki deneylerde kullanılan 9 adet girdi sırasıyla *VücutİvmeX*, *VücutİvmeY*, *VücutİvmeZ*, *VücutJiroskopX*, *VücutJiroskopY*, *VücutJiroskopZ*, *ToplamYerçekimselİvmeX*, *ToplamYerçekimselİvmeY* ve *ToplamYerçekimselİvmeZ* olarak verilirken, WISDM veri kümesi için çalışmamızdaki deneylerde kullanılan 3 adet girdi sırasıyla *İvmeX*, *İvmeY* ve *İvmeZ* olarak verilmektedir. WISDM ve UCI veri kümesi için *İvme* cinsi girdiler (öznitelikler) İGAV veri kümesinde de olduğu gibi duyargalardan ham olarak elde edilmiş sinyal verilerinden oluşmaktadır. *ToplamYerçekimselİvme* cinsi girdiler UCI veri kümesinin kendi özelinde duyargalarla elde edilen sinyallerde insan vücudunun etkisi yanı sıra yerçekiminin etkisinin de ölçülmesiyle oluşturulan girdiler (öznitelikler) olarak verilmiştir. Tablo 5'de, UCI veri kümesi kullanılarak farklı mimariler üzerinde gerçekleştirilen deneylerin eğitim ve test sonuçları verilmiştir. 9 adet girdi ile ilgili öznitelikler alınarak ve girdi verisinin parçalanma



Şekil 5. Yazılımsal aracın (a) Veri kümesi göster butonu özelliği (b) Ekran çıktısı gösterimi butonu özelliği
(Software tool's (a) property to show given dataset (b) property to show screen output via related button)

büyüklüğü (batch size) 32 olan deneylerde kullanılan UCI veri kümesi %70'i eğitim sırasında, %30'u ise test işlemlerinde kullanılmak üzere ikiye bölünmüştür. Tablo 5'deki test doğruluğu sütunundaki değerlerin ortalaması alındığında görüldüğü üzere deneylerdeki herhangi bir TSA veya ESA modeli kullanılarak UCI veri kümesi için ortalama %91,9 test başarımlı doğruluğuna ulaşabilmektedir. UCI veri kümesi ile gerçekleştirilen bütün deneyler göz önüne alındığında; erken durdurma açıkken çift yönlü KTB modeliyle 24 eğitim yinleme sayısında tamamlanan deneydeki 6 farklı tipteki günlük insan aktivitesinin

sınıflandırılması çalışması için %93,82 test doğruluğunda en iyi başarımlı elde edilmiştir.

Tablo 6'da UCI veri kümesi için 6 farklı aktivite sınıfı üzerinden yapılan deneylerde elde edilen deneysel sonuçlar olarak başarımlı ölçütleri (performance metrics) bazında ağırlıklı ortalamaların alınmasıyla hesaplanan duyarlılık, anma ve F1 skoru değerleri verilmektedir. Ayrıca, deneyler sonucunda elde edilen ortalama AİK eğrisi için EAKA değeri ve buna dair standart sapma değerine de Tablo 6'da yer verilmiştir.

Tablo 6'da en yüksek duyarlık değeri (0,9400) ve en yüksek anma değeri (0,9383) deneylerde çift yönlü KTB modeliyle (Tablo 6'da ÇY KTB olarak verilmiştir) erken durdurma açık iken eğitim yineleme sayısı 24 olduğunda elde edilmiştir. Tabloda koyu harfle gösterilmektedir. Bu değerlerin 1 değerine yaklaştığı deneysel sonuçlarda ilgili modelin bir sınıflandırıcı olarak daha yüksek başarıma ulaştığı görülmektedir. Burada çift yönlü KTB ile F1 skoru için yüzdelik oran olarak yüksek olan değere (%93,91) sahip

model olduğu ve böylece sınıflandırma başarımları açısından diğer modellere göre en yüksek başarıma sahip olduğu anlaşılmaktadır. Ayrıca, ortalama AİK eğrisi EAKA değeri 1 değerine ne kadar yaklaşırsa ilgili sınıflandırıcının sınıfları ayırtmadaki ayırtıcılığının o kadar yüksek olduğu ve model başarımının yüksek olduğu anlaşılmaktadır. Bu bakış açısıyla, UCI veri kümesi için tablodaki tüm bu ölçütler göz önüne alındığında çift yönlü KTB modelinin en yüksek başarıma sahip olduğu açıkça görülmektedir.

Tablo 5. UCI veri kümesi için eğitim ve test sonuçları (Training and testing results for UCI dataset)

Kullanılan Mimari Model	Erken Durdurma	Eğitim Yineleme Sayısı	Eğitim Kaybı	Eğitim Doğruluğu(%)	Test Kaybı	Test Doğruluğu(%)
UKSB	Kapalı	150	0,09462	96,16	0,38495	89,54
UKSB	Açık	33	0,11444	95,34	0,28037	92,09
ÇY UKSB	Kapalı	150	0,07876	96,57	0,41844	91,04
ÇY UKSB	Açık	19	0,11748	95,13	0,28736	91,85
KTB	Kapalı	150	0,01048	99,72	0,33836	92,56
KTB	Açık	28	0,07568	96,92	0,27143	92,33
ÇY KTB	Kapalı	150	0,01305	99,53	0,39615	91,68
ÇY KTB	Açık	24	0,06471	97,30	0,24843	93,82
1B ESA	Kapalı	150	0,04118	98,27	0,64093	91,58
1B ESA	Açık	16	0,09452	95,91	0,32786	92,53

*ÇY: Çift yönlü

Tablo 6. UCI veri kümesi için tüm aktivite sınıfları üzerinden ölçüt bazında başarımlar sonuçları (Metric-based performance results through all classes of activities for UCI dataset)

Kullanılan Mimari Model	Erken Durdurma	Eğitim Yineleme Sayısı	Ağırlıklı Ortalama Duyarlık	Ağırlıklı Ortalama Anma	Ağırlıklı Ortalama F1 skoru (%)	Ortalama AİK eğrisi EAKA değeri ve std. sapması
UKSB	Kapalı	150	0,8983	0,9000	89,91	0,9844±0,0095
UKSB	Açık	33	0,9233	0,9233	92,33	0,9859±0,0098
ÇY UKSB	Kapalı	150	0,9116	0,9116	91,16	0,9783±0,0116
ÇY UKSB	Açık	19	0,9183	0,9183	91,83	0,9848±0,0091
KTB	Kapalı	150	0,9250	0,9266	92,57	0,9900±0,0066
KTB	Açık	28	0,9250	0,9266	92,57	0,9902±0,0065
ÇY KTB	Kapalı	150	0,9183	0,9183	91,83	0,9889±0,0085
ÇY KTB	Açık	24	0,9400	0,9383	93,91	0,9890±0,0102
1B ESA	Kapalı	150	0,9183	0,9033	91,07	0,9867±0,0107
1B ESA	Açık	16	0,9283	0,9266	92,74	0,9873±0,0111

*ÇY: Çift yönlü

Tablo 7. WISDM veri kümesi için eğitim ve test sonuçları (Training and testing results for WISDM dataset)

Kullanılan Mimari Model	Erken Durdurma	Eğitim Yineleme Sayısı	Eğitim Kaybı	Eğitim Doğruluğu(%)	Test Kaybı	Test Doğruluğu(%)
UKSB	Kapalı	150	0,00107	99,98	0,08987	98,27
UKSB	Açık	56	0,05662	98,37	0,07053	98,08
ÇY UKSB	Kapalı	150	0,00041	100	0,06535	98,33
ÇY UKSB	Açık	44	0,06464	97,59	0,08394	97,26
KTB	Kapalı	150	0,00018	100	0,08793	98,51
KTB	Açık	21	0,02882	99,08	0,09627	97,66
ÇY KTB	Kapalı	150	0,00010	100	0,08083	98,17
ÇY KTB	Açık	38	0,00128	99,94	0,08275	98,27
1B ESA	Kapalı	150	0,00067	99,96	0,09522	98,81
1B ESA	Açık	27	0,01316	99,67	0,04989	99,09

*ÇY: Çift yönlü

Tablo 8. WISDM veri kümesi için tüm aktivite sınıfları üzerinden ölçüt bazında başarımlar sonuçları
(Metric-based performance results through all classes of activities for WISDM dataset)

Kullanılan Mimari Model	Erken Durdurma	Eğitim Yineleme Sayısı	Ağırlıklı Ortalama Duyarlık	Ağırlıklı Ortalama Anma	Ağırlıklı Ortalama F1 skoru (%)	Ortalama AİK eğrisi EAKA değeri ve std. sapması
UKSB	Kapalı	150	0,9766	0,9750	97,57	0,9940±0,0011
UKSB	Açık	56	0,9683	0,9733	97,07	0,9943±0,0006
ÇY UKSB	Kapalı	150	0,9750	0,9733	97,41	0,9946±0,0006
ÇY UKSB	Açık	44	0,9616	0,9533	95,74	0,9939±0,0015
KTB	Kapalı	150	0,9733	0,9733	97,33	0,9945±0,0003
KTB	Açık	21	0,9666	0,9633	96,49	0,9934±0,0013
ÇY KTB	Kapalı	150	0,9750	0,9633	96,91	0,9945±0,0004
ÇY KTB	Açık	38	0,9750	0,9733	97,41	0,9944±0,0005
1B ESA	Kapalı	150	0,9800	0,9833	98,16	0,9946±0,0005
1B ESA	Açık	27	0,9883	0,9850	98,66	0,9947±0,0002

*ÇY: Çift yönlü

Tablo 7’de WISDM veri kümesi ile gerçekleştirilen deney sonuçlarına yer verilmiştir. 3 adet girdi ile ilgili özneliklerin alınmasıyla ve girdi verisinin parçalanma büyüklüğü 32 olan WISDM veri kümesinin deneylerinde UCI veri kümesinde olduğu gibi %70’lik bölümü eğitim aşamasında kullanılırken, %30’luk kısmı ise test aşamasında kullanılmıştır. Tablo 7’deki test doğruluğu sütunundaki değerlerin ortalaması alındığında görülebileceği gibi deneylerde kullanılan tüm modellerden herhangi bir TSA veya ESA modeli kullanıldığında ortalama %98,24 test başarımlar doğruluğuna WISDM veri kümesi için ulaşılmıştır.

WISDM veri kümesi ile yapılan tüm deneyler içinden, 1 Boyutlu ESA ağı mimari modelinin kullanıldığı, erken durdurmanın açık halde olduğu ve deneydeki eğitim yineleme sayısının 27 olduğu deneyde en iyi başarımlar oranı elde edilmiştir. Bu deneyde, 6 farklı tipteki günlük insan aktivitesini sınıflandırmada %99,09 test doğruluğuna ulaşılmıştır. Ravi vd. [42] çalışmasında WISDM veri kümesini kullanarak %98,6 oranında bir başarımlar elde edilmiştir. Benzer bir diğer çalışmada Chen vd. [8], WISDM veri kümesi ile %92,1’lik bir başarımlar elde edilmiştir. Bunlar gibi literatürdeki gerçekleştirilen diğer çalışmalar ile kıyaslandığında bu çalışmamızda verilen WISDM veri kümesi deneylerindeki test doğruluk değerleri göz önüne alındığında çalışmamızın oldukça yüksek bir başarımlar sonucu elde ettiği görülmektedir.

Tablo 8’de WISDM veri kümesi için 6 farklı aktivite sınıfı üzerinden yapılan deneylerde elde edilen deneysel sonuçlar olarak başarımlar ölçütleri bazında ağırlıklı ortalamaların alınmasıyla hesaplanan duyarlık, anma ve F1 skoru değerleri verilmektedir. Ayrıca, deney sonucu oluşan ortalama AİK eğrisi için EAKA değeri ve buna dair standart sapma değerine de Tablo 8’de yer verilmiştir.

Tablo 8’de en yüksek duyarlık değeri (0,9883) ve en yüksek anma değeri (0,9850) deneylerde 1 Boyutlu ESA modeliyle (Tablo 8’de 1B ESA olarak verilmiştir) erken durdurma açık iken eğitim yineleme sayısı 27 olduğunda elde edilmiştir. Tabloda koyu harfle gösterilmektedir. Bu değerler 1

değerine yaklaştıkça ilgili modelin sınıflandırıcılığı sayesinde daha yüksek sınıflandırma başarımlarına ulaşılmaktadır. Buradaki, 1 Boyutlu ESA modeli için F1 skoru, yüzdelik oran olarak en yüksek olan değer (%98,66) olarak elde edilmiştir. Böylece, bu modelin sınıflandırma başarımlar açısından diğer modeller göz önüne alındığında WISDM veri kümesi için en yüksek başarımlar sahip olduğunu görülmektedir. Ayrıca, 1 Boyutlu ESA modelinin WISDM veri kümesi için ortalama AİK eğrisi EAKA değeri 1 değerine oldukça fazla yaklaştığı görülmektedir. Bu açıdan, bu modelin sahip olduğu insan günlük aktivitelerini sınıflandırmadaki sınıflar arası ayrıştırıcılığının oldukça yüksek olduğu ve bu nedenle modelin doğru aktivite sınıflarına dair sınıflandırma başarımlarının da yüksek olduğu anlaşılmaktadır.

Tablo 9’da ham jiroskop ve ivmeölçer duyarga verileri ile oluşturulan İGAV kümesi üzerinde yapılan deneylere ilişkin eğitim ve test sonuçlarına yer verilmiştir. Gerçekleştirilen deneylerde yukarıda belirtilen halkın kullanımına açık hazır veri kümelerinde olduğu gibi veri kümesinin %70’lik kısmı eğitimde ve %30’luk kısmı ise test aşamasında kullanılmıştır. 6 adet girdi ile ilgili öznelikler alınarak ve girdi verisinin parçalanma büyüklüğü 32 verilerek İGAV ham veri kümesini kullanılmasıyla işlem yaptırılan derin ağ mimari modellerinden bu deneylerde kullanılan tüm modeller göz önüne alındığında herhangi bir TSA veya ESA modeli kullanıldığında ortalama %96,84 test başarımlar doğruluğu elde edilmiştir. Çift yönlü KTB modeli, erken durdurma kapalıyken, eğitim yineleme sayısı 150 olduğunda, 7 farklı tipteki günlük insan aktivitesinin sınıflandırılma çalışmasında test doğruluğu olarak %97,85 başarımlar elde etmiştir. Bu sonuç, İGAV kümesi kullanılarak gerçekleştirilen deneyler arasındaki en iyi sonuç olarak elde edilmiştir. Şekil 6’da çift yönlü KTB ağ modelinin İGAV ham veri kümesi için sınıflandırma çalışması yapılan 7 farklı tipteki insan günlük aktivitesine dair karmaşıklık matrisi ve deney sonucu oluşan ortalama AİK eğrisi bulunmaktadır.

Şekil 6’daki (a) karmaşıklık matrisi incelendiğinde, satır değerleri kullanılan modelin gerçek sınıf aktivitelerinin kaç

Tablo 9. İGAV ham veri kümesi için eğitim ve test sonuçları (Training and testing results for IGAV raw dataset)

Kullanılan Mimari Model	Erken Durdurma	Eğitim Yineleme Sayısı	Eğitim Kaybı	Eğitim Doğruluğu(%)	Test Kaybı	Test Doğruluğu(%)
UKSB	Kapalı	150	0,00255	100	0,16457	96,02
UKSB	Açık	58	0,03431	99,14	0,13965	96,50
ÇY UKSB	Kapalı	150	0,00147	100	0,15404	96,66
ÇY UKSB	Açık	45	0,00305	99,93	0,14146	97,14
KTB	Kapalı	150	0,00458	99,96	0,11708	96,98
KTB	Açık	35	0,00932	99,76	0,10259	97,22
ÇY KTB	Kapalı	150	0,00073	100	0,07913	97,85
ÇY KTB	Açık	27	0,01287	99,76	0,08393	97,77
1B ESA	Kapalı	150	0,01213	99,69	0,15376	96,74
1B ESA	Açık	29	0,06191	98,09	0,19526	95,55

*ÇY: Çift yönlü

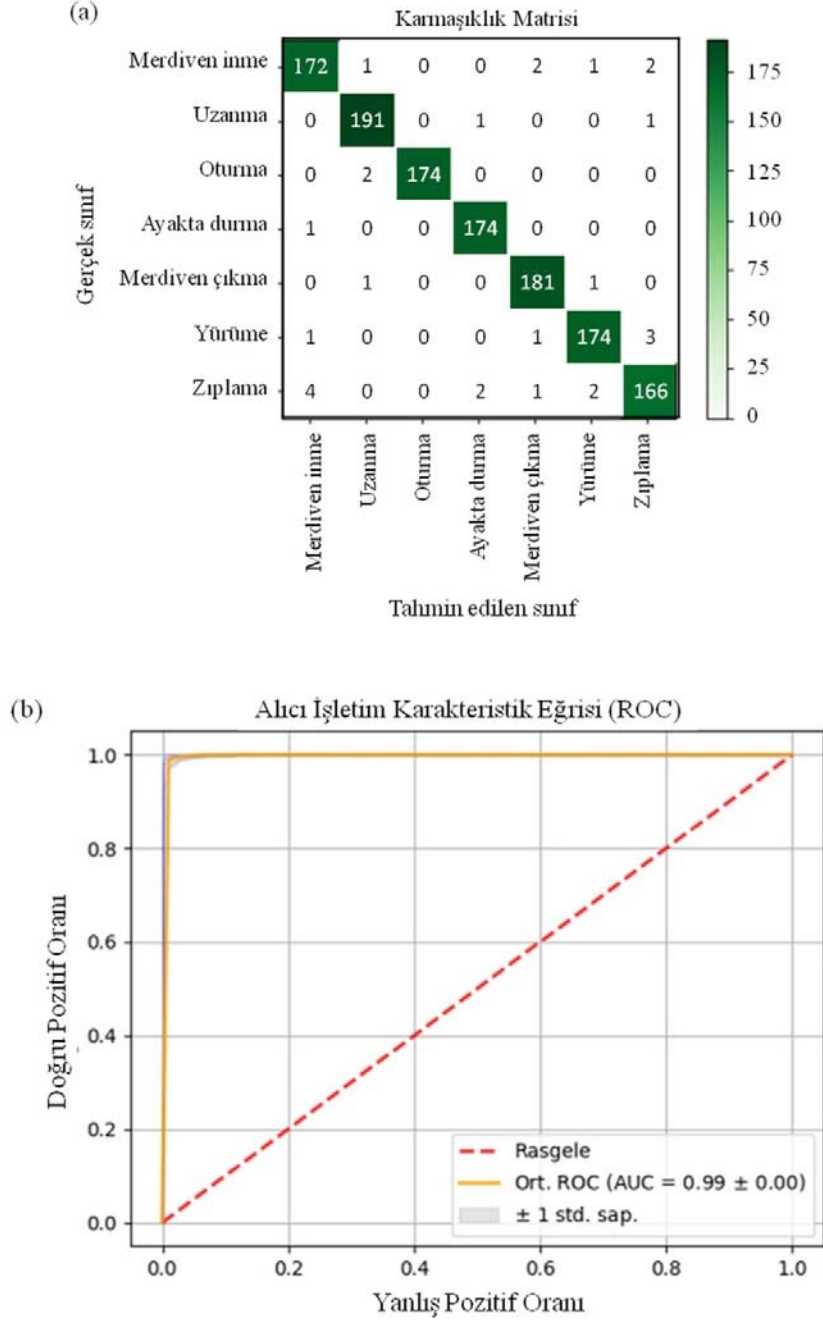
Tablo 10. İGAV ham veri kümesi için tüm aktivite sınıfları üzerinden ölçüt bazında başarımlar sonuçları (Metric-based performance results through all classes of activities for IGAV raw dataset)

Kullanılan Mimari Model	Erken Durdurma	Eğitim Yineleme Sayısı	Ağırlıklı Ortalama Duyarlık	Ağırlıklı Ortalama Anma	Ağırlıklı Ortalama F1 skoru (%)	Ortalama AİK eğrisi EAKA değeri ve std. sapması
UKSB	Kapalı	150	0,9614	0,9600	96,06	0,9931±0,0021
UKSB	Açık	58	0,9628	0,9642	96,34	0,9934±0,0019
ÇY UKSB	Kapalı	150	0,9657	0,9642	96,49	0,9926±0,0039
ÇY UKSB	Açık	45	0,9714	0,9714	97,14	0,9928±0,0031
KTB	Kapalı	150	0,9685	0,9700	96,92	0,9944±0,0012
KTB	Açık	35	0,9728	0,9714	97,20	0,9937±0,0019
ÇY KTB	Kapalı	150	0,9800	0,9785	97,92	0,9945±0,0005
ÇY KTB	Açık	27	0,9785	0,9771	97,77	0,9943±0,0008
1B ESA	Kapalı	150	0,9671	0,9657	96,63	0,9934±0,0023
1B ESA	Açık	29	0,9571	0,9542	95,56	0,9918±0,0047

*ÇY: Çift yönlü

adet olduğunu göstermektedir. Sütun verilerine bakıldığında, tahmin edilen sınıf aktivitelerinin kaç adet olduğu görülmektedir. Karmaşıklık matrisi incelendiğinde; uzanma aktivitesi için 191 değeri ile deneyde kullanılan ilgili ağ mimarisi sayesinde oldukça iyi bir sınıflandırma yapıldığı da gözlemlenmektedir. Deneyin ağırlıklı ortalaması alınmış başarımlar ölçüt sonuçları deneysel test sonuçları olarak duyarlık, anma ve F1 skoru için tüm aktivite sınıflarının ağırlıklı ortalaması üzerinden hesaplanmasıyla F1 skoru için yaklaşık olarak %98 değerine ulaşılmıştır. EAKA değeri, AİK eğrisi altında kalan kısım için hesaplanan değer olarak belirtilmektedir. Grafikte eğri tarafından kapsanan alanın büyüklüğü modelin başarısı ile doğrudan ilgilidir. Buna göre; modelin ayırt etme gücü EAKA değeri 1'e yaklaştıkça artmaktadır. İnsan aktivitesi sınıfları üzerinden elde edilmiş ortalama sınıflandırma başarımları AİK eğrisi grafiğinde gösterilmektedir. Şekil 6'daki (b) AİK eğrisi için düz çizgi (sarı renkli) ise bütün aktivite sınıfları hesaba katılarak oluşturulan AİK ortalamasını belirterek modelin genel doğruluğunu göstermektedir. Eğrinin sol üst köşeye oldukça yakın olması deneydeki sınıflandırmanın yüksek başarımlar doğruluğunu göstermektedir. Kırmızı kesikli çizgi ise rasgele (varsayılan) yapılabilen sınıflandırmayı gösteren referanstır. Tablo 10'da İGAV ham veri kümesi için 7 farklı aktivite sınıfı üzerinden yapılan deneylerde elde edilen deneysel sonuçlar olarak başarımlar ölçütleri bazında ağırlıklı

ortalamların alınmasıyla hesaplanan duyarlık, anma ve F1 skoru değerleri verilmektedir. Ayrıca, deney sonucu oluşan ortalama AİK eğrisi için EAKA değeri ve buna dair standart sapma değerine de Tablo 10'da yer verilmiştir. Tablo 10'da en yüksek duyarlık değeri (0,9800) ve en yüksek anma değeri (0,9785) deneylerde çift yönlü KTB modeliyle (Tablo 10'da ÇY KTB olarak verilmiştir) erken durdurma kapalı iken eğitim yineleme sayısı 150 olduğunda elde edilmiştir. Tabloda koyu harfle gösterilmektedir. Bu değerler 1 değerine yaklaştıkça ilgili modelin sınıflandırıcılığı sayesinde daha yüksek sınıflandırma başarımına ulaşılmaktadır. Buradaki, çift yönlü KTB modeli için F1 skoru, yüzdelik oran olarak en yüksek olan değer (%97,92) olarak elde edilmiştir. Böylece, bu modelin sınıflandırma başarımları açısından diğer modeller göz önüne alındığında İGAV ham veri kümesi için en yüksek başarımlara sahip olduğu görülmektedir. Ayrıca, çift yönlü KTB modelinin İGAV ham veri kümesi üzerinden elde edilen ortalama AİK eğrisi için EAKA değerinin 1 değerine oldukça fazla yaklaştığı da Tablo 10'dan görülmektedir. Bu açıdan bu modelin sahip olduğu insan günlük aktivitelerini sınıflandırmadaki sınıflar arası ayrıştırıcılığının oldukça yüksek olduğu ve bu nedenle modelin doğru aktivite sınıflarına dair sınıflandırma başarımının da yüksek olduğu anlaşılmaktadır. Ayrıca; literatürde gerçekleştirilen bir çalışmada F1 skoru zıplama aktivitesi için %93 olarak tespit



Şekil 6. Çift yönlü KTB ağ modelinin İGAV ham veri kümesi üzerinden yapılan teste elde edilen (a) karmaşıklık matrisi (b) AİK eğrisi

(Obtained results by the testing of bidirectional GRU network model on IGAV raw data which is shown as (a) confusion matrix (b) ROC curve)

edilmiştir [36]. Çift yönlü KTB modelinin İGAV ham veri kümesi üzerinde kullanımı yoluyla gerçekleştirilen deneyde zıplama aktivitesi için F1 skor değeri %96 olarak sonucuna ulaşılmıştır. Bu sonuç, çalışmamız kapsamında oluşturulan veri kümesi ile elde edilen sonuçların literatürdeki sınıflandırma çalışmalarına yakın başarıma ulaştığını göstermektedir. Tablo 11'de İGAV veri kümesinin alt kümelerine ait eğitim ve test sonuçları verilmiştir. İGAV-2 veri alt kümesi, yalnızca ham ivmeölçer verilerinden oluşan

3 adet öznitelik ve girdi verisinin parçalanma büyüklüğü 32 olan alt veri kümesidir. İGAV-2 veri alt kümesi için 3 adet öznitelik sırasıyla; *İvmeX*, *İvmeY*, *İvmeZ* olarak verilmektedir. İGAV-3 veri alt kümesi için Butterworth alçak geçiren filtresi, ham jiroskop ve ivmeölçer duyarga verilerine uygulanmış böylece oluşturulan 6 adet özniteliği içeren bir alt veri kümesi elde edilmiştir. İGAV-3 veri alt kümesi için 6 adet öznitelik sırasıyla; *ButterİvmeX*, *ButterİvmeY*, *ButterİvmeZ*, *ButterJiroskopX*,

ButterJiroskopY ve *ButterJiroskopZ* olarak verilmektedir. Ayrıca ilgili deneylerde girdi verisinin parçalanma büyüklüğü 32 olarak alınmıştır. Deneyler incelendiğinde *İGAV-3* veri alt kümesi kullanılarak çift yönlü KTB derin mimari modeliyle erken durdurma kapalı olarak 150 eğitim yineleme sayısınca gerçekleştirilen deneyde %96,82 test doğruluğuna ulaşıldığı Tablo 11'den görülmektedir. Tablo 12'de *İGAV* veri alt kümeleri için 7 farklı aktivite sınıfı üzerinden yapılan deneylerde elde edilen en iyi deneysel sonuçlardaki başarımlar ölçütleri bazında ağırlıklı ortalamaların alınmasıyla hesaplanan duyarlık, anma ve F1 skoru değerleri verilmektedir. Ayrıca, deney sonucu oluşan ortalama AİK eğrisi için EAKA değeri ve buna dair standart sapma değerine de Tablo 12'de yer verilmiştir. Tablo 12'de en yüksek duyarlık değeri (0,9700) ve en yüksek anma değeri (0,9700) *İGAV-3* veri alt kümesi üzerinde yapılan deneylerde çift yönlü KTB modeliyle (Tablo 12'de ÇY KTB olarak verilmiştir) erken durdurma kapalı iken eğitim yineleme sayısı 150 olduğunda elde edilmiştir. Tabloda koyu harfle gösterilmektedir. Bu değerler 1 değerine yaklaştıkça ilgili modelin sınıflandırmadaki yeteneği sayesinde daha yüksek sınıflandırma başarımına ulaşmaktadır. Buradaki,

çift yönlü KTB modeli için F1 skoru, yüzdelik oran olarak en yüksek olan değer (%97,00) olarak elde edilmiştir. Böylece, bu modelin sınıflandırma başarımı açısından diğer modeller göz önüne alındığında hem *İGAV-2* hem de *İGAV-3* veri alt kümelerine bakılarak en yüksek başarıma sahip olduğu görülmektedir. Ayrıca, çift yönlü KTB modelinin *İGAV-3* veri alt kümesi üzerinden elde edilen ortalama AİK eğrisi için EAKA değerinin 1 değerine oldukça fazla yaklaştığı da Tablo 12'den görülmektedir. Bu bakış açısıyla, bu modelin sahip olduğu insan günlük aktivitelerini sınıflandırmadaki sınıflar arası ayrıştırıcılığının oldukça yüksek olduğu ve bu nedenle modelin doğru aktivite sınıflarına dair sınıflandırma başarımının da yüksek olduğu ilgili *İGAV-2* ve *İGAV-3* veri alt kümeleri ile yapılan deneylerden de anlaşılmaktadır.

Bu çalışmada, insanların günlük aktivitelerinin sınıflandırılma çalışmaları gerçekleştirilerek analizler yapılmıştır. Oluşturulan TSA modelleri ve ESA modeli aktivite sınıflandırmada UCI, WISDM ve çalışmamızda oluşturulan yeni veri kümesi *İGAV* ile test edilmiştir. Çalışma kapsamında toplam 120 adet deney

Tablo 11. *İGAV* veri alt kümeleri kullanılarak elde edilen en iyi başarıma sahip eğitim ve test sonuçları
(Training and testing results with best performance obtained by using the *İGAV* data subsets)

Kullanılan Mimari Model	Veri Kümesi	Erken Durdurma	Eğitim Yineleme Sayısı	Eğitim Kaybı	Eğitim Doğruluğu (%)	Test Kaybı	Test Doğruluğu (%)
UKSB	<i>İGAV-2</i>	Kapalı	150	0,00578	99,93	0,22193	95,07
UKSB	<i>İGAV-2</i>	Açık	56	0,07267	97,61	0,19030	94,51
ÇY UKSB	<i>İGAV-3</i>	Kapalı	150	0,00172	100	0,15600	96,26
ÇY UKSB	<i>İGAV-3</i>	Açık	70	0,06569	97,82	0,22878	93,32
KTB	<i>İGAV-2</i>	Kapalı	150	0,00831	99,93	0,18403	95,63
KTB	<i>İGAV-2</i>	Açık	43	0,05116	98,36	0,16441	94,67
ÇY KTB	<i>İGAV-3</i>	Kapalı	150	0,00193	100	0,11291	96,82
ÇY KTB	<i>İGAV-2</i>	Açık	52	0,00531	99,32	0,13457	96,42
1B ESA	<i>İGAV-2</i>	Kapalı	150	0,02294	99,25	0,21521	94,75
1B ESA	<i>İGAV-2</i>	Açık	66	0,05956	97,78	0,22169	94,67

*ÇY: Çift yönlü

Tablo 12. *İGAV* veri alt kümeleri için tüm aktivite sınıfları üzerinden en iyi başarıma ulaşıldığında elde edilen ölçüt bazında başarımlar sonuçları

(Metric-based performance results when the best performance is achieved through all classes of activities for *İGAV* data subsets)

Kullanılan Mimari Model	Veri Kümesi	Erken Durdurma	Eğitim Yineleme Sayısı	Ağırlıklı Ortalama Duyarlık	Ağırlıklı Ortalama Anma	Ağırlıklı Ortalama F1 skoru (%)	Ortalama AİK eğrisi EAKA değeri ve std. sapması
UKSB	<i>İGAV-2</i>	Kapalı	150	0,9514	0,9500	95,06	0,9908±0,0052
UKSB	<i>İGAV-2</i>	Açık	56	0,9442	0,9442	94,42	0,9911±0,0053
ÇY UKSB	<i>İGAV-3</i>	Kapalı	150	0,9628	0,9628	96,28	0,9931±0,0015
ÇY UKSB	<i>İGAV-3</i>	Açık	70	0,9342	0,9342	93,42	0,9909±0,0050
KTB	<i>İGAV-2</i>	Kapalı	150	0,9557	0,9542	95,49	0,9924±0,0036
KTB	<i>İGAV-2</i>	Açık	43	0,9457	0,9457	94,57	0,9917±0,0041
ÇY KTB	<i>İGAV-3</i>	Kapalı	150	0,9700	0,9700	97,00	0,9942±0,0007
ÇY KTB	<i>İGAV-2</i>	Açık	52	0,9614	0,9642	96,27	0,9934±0,0023
1B ESA	<i>İGAV-2</i>	Kapalı	150	0,9457	0,9485	94,70	0,9913±0,0053
1B ESA	<i>İGAV-2</i>	Açık	66	0,9485	0,9471	94,77	0,9905±0,0063

*ÇY: Çift yönlü

gerçekleştirilmiştir. Çalışmanın katkılarında bir diğeri ise oluşturulan İGAV kümesinin (alt kümeleri ile birlikte) literatürde yer alan çalışmalarda kullanılması için araştırmacılara derin sinir ağı modellerini kıyaslamalarına olanak sağlamasıdır.

5. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Günümüzde çeşitli duyarılardan elde edilen sinyal verilerinin işlenmesine dayanan çalışmalar literatürde oldukça popüler bir araştırma alanı olmuştur. Özellikle bu tip sinyal verilerinden elde edilen öznelikler literatürdeki ilgili çalışmalarda klasik makine öğrenmesi veya derin öğrenme teknikleri ile kullanılmakta, insan aktivitelerinin tespiti ve sınıflandırılması, bu aktiviteler sayesinde cinsiyet belirleme [43] gibi çeşitli konulardaki birçok problemin çözümü adına uygulamaya yönelik çalışmalar yapılmaktadır. Derin öğrenme ağı mimari modelleri gerçek hayattaki problemlere çözüm üreten birçok çalışmada sıklıkla kullanılmaktadır. Özellikle ham veriden otomatik olarak öznelik öğrenme yeteneği ve yüksek doğrulukta başarıyı sayesinde derin öğrenme modelleri gün geçtikçe çalışmalarda daha çok tercih edilir olmaktadır. Derin öğrenme için belli başlı ağı mimari modelleri çeşitli araştırma alanlarındaki çalışmalarda kullanılmaktadır. Literatürdeki örnek teşkil eden son yıllardaki güncel bazı çalışmalara baktığımızda; görüntü işleme tabanlı olarak köpeklerin davranışlarının incelenmesiyle bunlara dair verilerin daha hızlı bölgesel ESA ağı modeli ile sınıflandırılmasında [44], uydu duyarıları ile elde edilen hiperspektral görüntülerin ESA ağı modeli ile sınıflandırılmasında [45] ve ses sinyallerinin işlenmesi tabanlı olarak UKSB ağı modelinin kullanıldığı prozodik açıdan Türkçe ağız tanımda [46] derin öğrenme sayesinde yüksek doğrulukta başarıyı elde edildiği görülmektedir. Bu bakış açısıyla çalışmamızda duyarğa sinyallerinden elde edilen öznelikler kullanılarak derin öğrenme ağı mimari modelleriyle sınıflandırma yapılmasına dayanan uygulamaya yönelik bir çalışma yapılmıştır.

İnsanların günlük aktivitelerin tespiti için akıllı cihazlardaki mevcut duyarılar kullanılarak gerçek zamanlı ölçümler literatürdeki çeşitli çalışmalarda gerçekleştirilmektedir. Bu çalışmada, böyle bir bakış açısıyla üç eksenli jiroskop duyarısıyla ve üç eksenli ivmeölçer duyarısıyla elde edilen veriler üzerinde işlemler yapılmıştır. Buna göre; halkın kullanımına açık WISDM ve UCI veri kümelerinin yanı sıra çalışmadaki deneylerde kullanılmak üzere hazırlanmış ve literatüre yeni kazandırılan bir veri kümesi olan İGAV veri kümesi sunulmaktadır. Bu veri kümesi oluşturulurken aktivitenin sınıflandırılmasının gerçekleştirileceği ham veriler kendi rızalarıyla veri toplanmasına gönüllü 10 kişiden (5 erkek ve 5 kadın) gerçek zamanlı biçimde, iç ve dış mekân olan tamamen doğal ortamlarda (*in-the-wild*), üç eksenli jiroskop duyarıları ve üç eksenli ivmeölçer duyarıları sayesinde toplanmıştır. Özellikle belirli koşullarla kısıtlanmış bir laboratuvar ortamında veri edinimi yapılmayarak böyle bir aktivite sınıflandırma biçimindeki gerçek dünya probleminin

gerçekçi çözümüne dayanak olması sağlanmıştır. İGAV ve literatürde sıkça kullanılan iki farklı veri kümesi üzerinden 5 farklı derin mimari modelin deneysel sonuçları ele alınmıştır. Çalışmamızda gerçekleştirilen 120 farklı deney için sınıflandırma sonuçlarının elde edilebilmesi adına gerekli ağı parametrelerinin belirlenmesi, eğitim ve test işlemlerinin kullanıcı tarafından yapılabildiği ve kendisinin belirleyeceği parametreler ile deneyleri gerçekleştirebilmesine olanak sunan özgün bir yazılımsal araç ve bunun grafik kullanıcı arayüzü tasarlanarak bu deneylerde kullanılmıştır. İlk kez bu kapsamda tasarlanıp kullanılan bu yeni ve benzersiz yazılımsal aracın sunduğu grafik arayüz sayesinde kullanıcıya esnek bir deney ortamı sunulmuştur. Bu sayede kendi belirlediği parametreler doğrultusunda 5 farklı derin mimari modele dair kullanıcı tarafından tanımlanabilen ağı düzenlemeleri üzerinden farklı parametrelerle farklı deney düzenekleri kurarak ağı modellerini test etme ve birbirleriyle başarıyı yönünden kıyaslama imkânı da kullanıcılar için sağlanmıştır. Diğer benzer çalışmalardan farklı olarak çalışmamızın literatüre katkı sunan bir diğer önemli özelliği de bu kıyaslanmanın kullanıcıya zahmetsizce kullanılabileceği bir biçimde sunuluyor oluşudur.

Literatürdeki veri kümeleriyle yapılan deneylerde elde edilen en iyi sonuç; 1 Boyutlu ESA derin ağı mimarisinin kullanıldığı WISDM veri kümesi üzerinde gerçekleştirilen deneyde elde edilmiştir. Böylece; bu deney sonucunda %99,09 oranında test doğruluğu başarıyı elde edilmiştir. Ayrıca İGAV veri kümesinin (6 adet ham öznelik içeren hali) üzerinde çift yönlü UKSB derin öğrenme ağı mimarisi kullanılarak yapılan deneyde %97,85 oranında test doğruluğunda bir başarıyı elde edilmiştir. Bu nicel ve nesnel sonuçlardan anlaşıldığı üzere gerçekleştirilen çalışmada bireylere dair aktivite sınıflandırılmasında yüksek doğruluk oranında sınıflandırma çözümü sunulmaktadır. Çalışmamız araştırmacıların kullanımına sunulan yeni İGAV veri kümesinin daha fazla alt kümelerini elde etmek adına çeşitli farklı özneliklerin (GPS vb.), filtreleme ve düzenleme işlemlerinin de eklenmesi ile zenginleştirilerek genişletilebilmesi, günümüz trendlerine göre farklı yeni derin mimari modellerinin yazılımsal araca eklenmesi ve çeşitli melez yaklaşımlarla deney düzeneklerinin kurulabilmesi, eniyileme bileşenlerinin bu düzeneklere eklenebilmesi olanağı veya farklı sinerjik yaklaşımlar için birden çok derin öğrenme mimari kombinasyonunun bu düzenekler üzerinden yapılabilmesi olanağının sunulması önümüzdeki dönemlerde yeni çalışmalar için planlanmaktadır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Çalışmamızdaki duyarğa verilerinin edinimi aşamasında katkısı olan gönüllülere teşekkür ederiz.

KAYNAKLAR (REFERENCES)

1. Ranao, C.A. ve Cho, S., Human activity recognition using smartphone sensors with two-stage continuous

- hidden markov models, 10th International Conference on Natural Computation (ICNC), Xiamen, China, 681-686, 19-21 Ağustos 2014.
2. Sebestyen, G., Tirea, A., Albert, R., Monitoring human activity through portable devices, *Carpathian Journal of Electronic and Computer Engineering*, 5 (1), 101-106, 2012.
 3. Lima, W.S., Souto, E., Rocha, T., Pazzi, R.W., Pramudianto, F., User activity recognition for energy saving in smart home environment, *IEEE Symposium on Computers and Communication (ISCC)*, Larnaca, Cyprus, 751-757, 6-9 Temmuz, 2015.
 4. Liao, L., Patterson, D.J., Fox, D., Kautz, H., Learning and inferring transportation routines, *Artificial Intelligence*, 171 (5-6), 311-331, 2007.
 5. Khan, A. M., Lee, Y.K., Kim, T.S., Accelerometer signal-based human activity recognition using augmented autoregressive model coefficients and artificial neural nets, 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Vancouver, BC, Canada, 5172-5175, 20-25 Ağustos, 2008.
 6. Kwapisz, J.R., Weiss, G.M., Moore, S.A., Activity recognition using cell phone accelerometers, *ACM SIGKDD Explorations Newsletter*, 12 (2), 74-82, 2011.
 7. Du, Y., Fu, Y., Wang, L., Skeleton based action recognition with convolutional neural network, 3rd IAPR Asian Conference on Pattern Recognition (ACPR), Kuala Lumpur, Malaysia, 579-583, 3-6 Kasım, 2015.
 8. Chen, Y., Zhong, K., Zhang, J., Sun, Q., Zhao, X., LSTM networks for mobile human activity recognition, *International Conference on Artificial Intelligence: Technologies and Applications (ICAITA 2016)*, Bangkok, Thailand, 50-53, 24-25 Ocak, 2016.
 9. Fuentes, D., Gonzales-Abril, L., Angulo, C., Ortega, J.A., Online motion recognition using an accelerometer in a mobile device, *Expert Systems with Applications*, 39 (3), 2461-2465, 2012.
 10. Wang, J., Chen, R., Sun, X., She, M., Kong, L., Generative models for automatic recognition of human daily activities from a single triaxial accelerometer, *WCCI 2012 IEEE World Congress on Computational Intelligence via International Joint Conference on Neural Networks (IJCNN)*, Brisbane, QLD, Australia, 1-6, 10-15 Haziran, 2012.
 11. Reyes-Ortiz, J.-L., Oneto, L., Samà, A., Parra, X., Anguita, D., Transition-Aware Human Activity Recognition Using Smartphones, *Neurocomputing*, 171 (1), 754-767, 2016.
 12. Zhang, S., Wei, Z., Nie, J., Huang, L., Wang, S., Li, Z., A review on human activity recognition using vision-based method, *Journal of Healthcare Engineering*, Article ID 3090343, 2017.
 13. Ustev, Y.E., Incel, O.D., Ersoy, C., User, device and orientation independent human activity recognition on mobile phones: challenges and a proposal, *UbiComp'13 Adjunct: Proceedings of the 2013 ACM conference on Pervasive and ubiquitous computing adjunct publication*, Zurich, Switzerland, 1427-1436, 8-12 Eylül, 2013.
 14. Su, X., Tong, H. ve Ji, P., Activity recognition with smartphone sensors, *Tsinghua Science and Technology*, 19 (3), 235-249, 2014.
 15. Gunduz, H. ve Cataltepe, Z., Borsa Istanbul (BIST) daily prediction using financial news and balanced feature selection, *Expert Systems with Applications*, 42 (22), 9001-9011, 2015.
 16. 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, Newcastle, UK, 17-24, 18-22 Haziran, 2012.
 17. Yavuz, S. ve Deveci, M., İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187, 2012.
 18. Oğuzlar, A., Veri ön işleme, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21 (0), 67-76, 2003.
 19. Kumar, A., Human activity recognition through smartphone's tri-axial accelerometer using time domain wave analysis and machine learning, *International Journal of Computer Applications*, 127 (18), 22-26, 2015.
 20. Khan, A.M., Lee, Y.K., Lee, S.Y., Kim, T.S., A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer, *IEEE Transactions on Information Technology in Biomedicine*, 14 (5), 1166-1172, 2010.
 21. Karasulu, B., Kısıtlanmış Boltzmann makinesi ve farklı sınıflandırıcılarla oluşturulan sınıflandırma iş hatlarının başarılarının değerlendirilmesi, *Bilişim Teknolojileri Dergisi*, 11 (3), 223-233, 2018.
 22. UCI veri kümesi websitesi. Human activity recognition using smartphones dataset. [https:// archive. ics.uci. edu/ml/datasets/human+activity+recognition+using+smartphones](https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones). Erişim tarihi Temmuz 20, 2020.
 23. Anguita, D., Ghio, A., Oneto, L., Parra, X., Reyes-Ortiz, J.L., A public domain dataset for human activity recognition using smartphones, 21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN, Bruges, Belgium. 2013.
 24. WISDM veri kümesi websitesi. WISDM Lab Dataset. <https://www.cis.fordham.edu/wisdm/dataset.php>. Erişim tarihi Temmuz 20, 2020.
 25. Python programlama dili websitesi. [https:// www. python. org/](https://www.python.org/). Erişim tarihi Temmuz 20, 2020.
 26. Google Tensorflow websitesi. [https:// www. tensorflow. org/](https://www.tensorflow.org/). Erişim tarihi Temmuz 20, 2020.
 27. Keras websitesi. <https://keras.io/>. Erişim tarihi Temmuz 20, 2020.
 28. Python Tkinter GKA websitesi. [https:// docs.python.org /3/library/tk.html](https://docs.python.org/3/library/tk.html). Erişim tarihi Temmuz 20, 2020.
 29. Swift programlama dili websitesi. <https://swift.org/>. Erişim tarihi Temmuz 20, 2020.

30. Degtiarev, A., MotionCollector uygulaması kodları. <https://github.com/degtiarev/MotionCollector>. Erişim tarihi Temmuz 20, 2020.
31. Metin, İ.A., İnsanın Günlük Yaşam Aktivitelerinin Sınıflandırılmasında Derin Öğrenme Modellerinin Karşılaştırılması, Yüksek lisans tezi, Çanakkale Onsekiz Mart Üniversitesi, Fen Bilimleri Enstitüsü, Çanakkale, 2020.
32. Metin, İ.A. ve Karasulu, B., İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım, Veri Bilimi, 2 (2), 1-10, 2019.
33. Eşref, Y., Türkçe Dizi Etiketleme İçin Sinir Ağ Modelleri, Yüksek lisans tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2019.
34. Yang, Z., Salakhutdinov, R., Cohen, W., Multi-task cross-lingual sequence tagging from scratch, arXiv e-prints, 2016.
35. Schuster, M. ve Paliwal, K.K., Bidirectional recurrent neural networks, IEEE Transactions on Signal Processing, 45 (11), 2673-2681, 1997.
36. Lawal, I.A. ve Bano, S., Deep human activity recognition using wearable sensors, PETRA'19: Proceedings of the 12th ACM International Conference on Pervasive Technologies Related to Assistive Environments, Rhodes, Greece, 45-48, 5-7 Haziran, 2019.
37. LeCun, Y., Bottou, L., Bengio, Y., Haffner, P., Gradient-based learning applied to document recognition, Proceedings of the IEEE, 86 (11), 2278-2324, 1998.
38. Bengio, Y., Courville, A., Vincent, P., Representation learning: a review and new perspectives, IEEE Transactions on Software Engineering, 35 (8), 1798-1828, 2012.
39. Buduma, N., Fundamentals of Deep Learning, O'Reilly Media Inc., 2017.
40. Kingma, D.P. ve Ba, J., Adam: A Method for Stochastic Optimization, arXiv e-prints, 2014.
41. Metin, İ.A., Github websitesi. <https://github.com/ibrahimalimetin>. Erişim tarihi Temmuz 20, 2020.
42. 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 Journal of Biomedical and Health Informatics, 21 (1), 56-64, 2017.
43. 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), 2173-2185, 2019.
44. Dandil E., ve Polattimur R., Dog Behavior Recognition and Tracking based on Faster R-CNN, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (2), 819-834, 2020.
45. Hanbay K., Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (1), 443-456, 2020.
46. Işık G., ve Artuner H., Turkish dialect recognition in terms of prosodic by long short-term memory neural networks, Journal of the Faculty of Engineering and Architecture of Gazi University, 35 (1), 213-224, 2020.

