

T.C.  
İSTANBUL AYDIN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**CİHAZ SENSÖRLERİ İLE İNSAN AKTİVİTELERİNE DAYALI  
MAKİNE ÖĞRENMESİ**

**YÜKSEK LİSANS TEZİ**

**Muhammed Yusuf UYSAL**

**Bilgisayar Mühendisliği Anabilim Dalı  
Bilgisayar Mühendisliği Programı**

**MAYIS, 2024**



T.C.  
İSTANBUL AYDIN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**CİHAZ SENSÖRLERİ İLE İNSAN AKTİVİTELERİNE DAYALI  
MAKİNE ÖĞRENMESİ**

**YÜKSEK LİSANS TEZİ**

**Muhammed Yusuf UYSAL**  
(Y2113.010029)

**Bilgisayar Mühendisliği Anabilim Dalı**  
**Bilgisayar Mühendisliği Programı**

**Tez Danışmanı: Dr. Öğr. Üyesi Sina APAK**

**MAYIS, 2024**

## TEZ SINAV TUTANAĐI

İstanbul Aydın Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulu'nun 18.03.2024 tarih ve 2024.05 sayılı toplantısında oluşturulan jüri üyeleri önünde, 07/05/2024 tarihinde tez savunma sınavı yapılan Muhammed Yusuf UYSAL'ın tezi oybirliĐi ile kabul kararı verilmiştir.

### JÜRİ

1. Üye (Tez Danışmanı) : Dr. Öğr. Üyesi Sina APAK
2. Üye : Prof. Dr. Ali GÜNEŞ
3. Üye : Doç Dr. Melih KUNCAN

### ONAY

İstanbul Aydın Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulu'nun  
..... tarih ve ..... sayılı kararı

(\*) OybirliĐi/Oyçokluğu hâli yazı ile yazılacaktır.

(\*\*) Kabul kararı hâli yazı ile yazılacaktır

## ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduđum “CİHAZ SENSÖRLERİ İLE İNSAN AKTİVİTELERİNE DAYALI MAKİNE ÖĞRENMESİ” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça’da gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (07/05/2024)

Muhammed Yusuf UYSAL

## ÖNSÖZ

Tez çalışmamı gerçekleştirdiğim süre içerisinde bilgi birikimini ve desteğini esirgemeyen değerli annem, babam, eşim, çocuklarım ve hocam Dr. Öğr. Üyesi Sina APAK' a sonsuz teşekkür eder, saygılarımı sunarım.

Mayıs, 2024

UYSAL

Muhammed Yusuf

# CİHAZ SENSÖRLERİ İLE İNSAN AKTİVİTELERİNE DAYALI MAKİNE ÖĞRENMESİ

## ÖZET

Giyilebilir teknolojinin yaygınlaştığı çağdaş çağda, sensörlerin bu cihazlara entegrasyonu günlük hayata hızla nüfuz etti. İnsan Aktivitesi Tanıma (HAT) alanındaki gelişmeler özellikle dikkate değerdir; burada bir kişinin aktiviteleri, insan hareketlerine duyarlı sensörlerin kullanımı yoluyla fark edilir. Akıllı telefonlarda İnsan Aktivitesi Tanıma özelliğinin yaygınlaşması, kullanıcı deneyimlerini önemli ölçüde artırdı ve bu cihazların teknolojik yeteneklerini genişletti, sonuç olarak bireylerin günlük rutinlerinde her yerde bulunmalarını güçlendirdi.

İnsan Faaliyeti Tanıma' nın (HAT) önemi ve popülaritesi, akıllı telefonlar ve insan faaliyeti verilerini toplayabilen video kameralar gibi yakalama cihazlarının yaygın kullanımıyla kolaylaştırılan çeşitli uygulamalarla vurgulanmaktadır. Artan sayıda elektronik cihaz ve bunların uygulamalarının yapay zekada (AI) kaydedilen ilerlemelerle birleşmesi, gizli bilgilerin kesin tanıma ve yorumlama için çıkarılmasında devrim yarattı. Son yirmi yılda, İnsan Aktivitesi Tanıma (HAT), uzaktan sağlık izleme, güvenlik ve gözetim ve akıllı ortamların geliştirilmesi gibi çeşitli alanlarda uygulamalar bularak büyük ilgi gördü.

Bu bilimsel çaba, çeşitli makine öğrenimi sınıflandırma metodolojilerini kullanarak, akıllı telefon sensörlerini kullanan insan etkinliklerinin tanınmasına odaklanıyor. Özellikle akıllı telefonlara yerleştirilmiş ivmeölçer ve jiroskop sensörlerinden elde edilen veriler, insan faaliyetlerinin belirlenmesinde temel teşkil ediyor. Bu çalışmanın temel amacı, 18 farklı insan faaliyetini kapsayan akıllı telefon sensör verilerinin analizi yoluyla insan hareketlerinin tespit edilmesidir. Elde edilen veri kümesi, K-NN, Karar Ağacı, Rastgele Orman, SVM, LGBM Classifier, Bootstrap Aggregating Sınıflandırıcı, Evrimsel Sinir Ağları (CNN), ve Tekrarlayan Sinir Ağları (RNN) gibi farklı makine öğrenimi algoritmaları kullanılarak bir veri seti üzerinde sınıflandırma analizi gerçekleştirilmiştir.

Belirlenen sonuçlar,

K-NN tekniđi için en uygun komşu sayısı 17 olarak belirlenmiştir. Analiz sonuçlarına göre, en yüksek başarı oranı %97.76 ile FIX\_walking etiketinde, en düşük başarı oranı ise %76.42 ile SITTING etiketinde elde edilmiştir.

Karar Ağacı analizinde random\_state parametresi 8 olarak seçilmiş, tüm etiketler için ortalama başarı oranı %92.55 olarak tespit edilmiştir. Rastgele Orman Sınıflandırma sonuçlarına göre, max\_depth parametresi 2 olarak belirlenmiş ve en yüksek başarı %98.38 ile FIX\_walking etiketinde, en düşük başarı %78.28 ile SITTING etiketinde elde edilmiştir.

SVM analizinde gamma ve kernel parametreleri belirlenmiş, tüm etiketler için ortalama başarı oranı %87.55 olarak bulunmuştur. LGBMClassifier ile en yüksek başarı %98.13 ile SLEEPING etiketinde, en düşük başarı %90.32 ile SITTING etiketinde elde edilmiştir.

Bootstrap Aggregating Sınıflandırıcı analizinde en iyi başarı SLEEPING, en düşük başarı SITTING etiketinde elde edilmiş ve ortalama başarı oranı %94,22 olarak belirlenmiştir.

Evrişimsel Sinir Ağları (CNN) analizine göre en yüksek başarı %97.07 ile SLEEPING etiketinde, en düşük başarı %89,89 ile SITTING etiketinde elde edilmiştir.

Tekrarlayan Sinir Ağları (RNN) analizinde en yüksek başarı %96.27 ile FIX\_walking etiketinde, en düşük başarı %58.51 ile SITTING etiketinde elde edilmiştir. Tüm etiketlerin ortalama başarı oranı %93.84 olarak bulunmuştur.

Bu şekilde oluşturulan bu veri seti, yalnızca akıllı telefonlara ve diğer akıllı cihazlara yeni etkinlikleri tespit etme yetkisi vermekle kalmıyor, aynı zamanda araştırmacıların pratik İnsan Aktivitesi Tanıma (HAR) verilerine dayanan modelleri geliştirmeleri için değerli ampirik temeller sağlamaktadır.

**Anahtar Kelimeler:** Derin Öğrenme, Makine Öğrenmesi, İnsan aktivitesi tanıma, Akıllı sensör sistemleri

# **MACHINE LEARNING BASED ON HUMAN ACTIVITIES WITH DEVICE SENSORS**

## **ABSTRACT**

In the contemporary era, where wearable technology became widespread, the integration of sensors into these devices rapidly penetrated daily life. Developments in human activity recognition (line) field are particularly remarkable; Here, a person's activities are noticed by the use of sensors sensitive to human movements. The spread of human activity recognition on smartphones significantly increased user experiences and expanded the technological capabilities of these devices, as a result, strengthened individuals in their daily routines everywhere.

Human activity is emphasized by various applications that are facilitated by widespread use of capture devices such as the importance and popularity of recognition (line), smartphones and video cameras that can collect human activity data. The increasing number of electronic devices and their applications in artificial intelligence (AI) merged with the progresses recorded, and the release of confidential information for definitive recognition and interpretation. In the last twenty years, human activity recognition (line) has attracted great attention by finding applications in various fields such as remote health monitoring, safety and surveillance and development of smart environments.

This scientific effort focuses on the recognition of human activities using smartphone sensors using various machine learning methodologies. In particular, the data obtained from accelerator and gyroscope sensors placed on smartphones are the basis for determining human activities. The main purpose of this study is to detect human movements through the analysis of smartphone sensor data covering 18 different human activities. Classification analysis was performed on a data set using different machine learning algorithms such as data set, K-nn, decision tree, random forest, SVM, LGBMClassifier, Bootstrap Aggregating Classification, Evolutionary Neural Networks (CNN), and Recurrent Neural Networks (RNN).

### Determined Results,

The number of neighbors for the K-NN technique is determined as 17. According to the results of the analysis, the highest success rate was obtained on the FIX\_walking label with 97.76 % and the lowest success rate was obtained on the Sitting label with 76.42 %.

In the decision tree analysis, the random\_state parameter was selected as 8 and the average success rate for all labels was determined as 92.55 %. According to random forest classification results, the Max\_Depth parameter was determined as 2 and the highest success was obtained on the FIX\_walking label with 98.38 % and the lowest success was obtained on the Sitting label with 78.28 %.

In SVM analysis, gamma and kernel parameters were determined and the average success rate for all labels was 87.55 %. The highest success with LGBMClassifier was obtained on the Sleeping label with 98.13 % and the lowest success with 90.32 %.

The best achievement in Bootstrap Aggregating Classification Analysis Sleeping was obtained in the lowest success Sitting label and the average success rate was 94.22 %.

The highest success compared to evolutionic neural networks (CNN) analysis was achieved on the SLEEPING label with 97.07 % and the lowest success was obtained on the Sitting label with 89.89 %.

The highest success in recurrent neural networks (RNN) analysis was obtained on the FIX\_WALING label with 96.27 % and the lowest success was achieved on the Sitting label with 58.51 %. The average success rate of all labels was 93.84 %.

This data set, which is created in this way, not only gives smart phones and other smart devices to detect new events, but also provides valuable empirical foundations for researchers to develop models based on practical human activity recognition (HAR) data.

**Keywords:** Deep Learning, Machine Learning, Human activity recognition, Smart sensor systems

## İÇİNDEKİLER

ONUR SÖZÜ .....	iii
ÖNSÖZ.....	iv
ÖZET.....	v
ABSTRACT .....	vii
İÇİNDEKİLER .....	ix
ÇİZELGELER LİSTESİ.....	xi
ŞEKİLLER LİSTESİ.....	xii
<b>I. GİRİŞ.....</b>	<b>1</b>
<b>II. LİTERATÜR TARAMASI .....</b>	<b>3</b>
<b>III. MAKİNE ÖĞRENMESİNE VE DERİN ÖĞRENMEYE GİRİŞ.....</b>	<b>7</b>
A. Yapay Zekâ.....	7
B. Makine Öğrenmesi .....	8
1. Makine Öğrenmesi ve Yöntemleri .....	9
a. Denetimli öğrenme.....	9
b. Denetimsiz öğrenme.....	9
c. Yarı denetimli öğrenme.....	10
d. Takviyeli öğrenme .....	10
2. Makine Öğrenmesi Algoritmaları .....	11
a. K-En Yakın komşu algoritması.....	11
b. Destek vektör makineleri .....	11
c. Rastgele orman sınıflandırıcısı.....	12
d. Karar ağacı algoritması .....	13
C. Derin Öğrenme.....	15
1.Yapay Sinir Ağları .....	16
a. Tekrarlayan sinir ağları (RNN).....	18
b. Evrimsel sinir ağları (CNN) .....	19
<b>IV. UYGULAMA VE BULGULAR .....</b>	<b>22</b>
A. Araştırmanın Amacı .....	22

B. Veri Seti .....	22
C. Bulgular.....	23
1. K-NN Analiz Sonuçları.....	23
2. Karar Ağacı Analiz Sonuçları .....	25
3. Rastgele Orman Sınıflandırma Sonuçları.....	27
4. Destek Vektör Makineleri Analiz Sonuçları .....	29
5. LGBMClassifier Analiz Sonuçları.....	31
6. Bootstrap Aggregating Sınıflandırıcı .....	34
7. Evrimsel Sinir Ağları Analiz Sonuçları .....	36
8. Tekrarlayan Sinir Ağları Analiz Sonuçları.....	39
9. Topluluk Öğrenmesi (Ensemble Majority) .....	42
<b>V. SONUÇ .....</b>	<b>44</b>
<b>VI. KAYNAKLAR .....</b>	<b>46</b>
<b>ÖZGEÇMİŞ.....</b>	<b>57</b>

## ÇİZELGELER LİSTESİ

Çizelge 1 K-NN İçin Tüm Etiketler Hata Matrix'i .....	24
Çizelge 2 Karar Ağacı Algoritması İçin Tüm Etiketler Hata Matrix'i .....	27
Çizelge 3 RF Algoritması İçin Tüm Etiketler Hata Matrix'i .....	29
Çizelge 4 SVM Algoritması İçin Tüm Etiketler Hata Matrix'i .....	31
Çizelge 5 LGBMClassifier Algoritması İçin Tüm Etiketler Hata Matrix'i .....	33
Çizelge 6 BaggingClassifier Algoritması İçin Tüm Etiketler Hata Matrix'i .....	36
Çizelge 7 CNN İçin Tüm Etiketlerin Hata Matrix'i .....	39
Çizelge 8 CNN İçin Tüm Etiketlerin Hata Matrix'i .....	42

## ŞEKİLLER LİSTESİ

Şekil 1 Sinir Hücrelerinin Modellenmesi.....	16
Şekil 2 YSA Yapısı.....	17
Şekil 3 Yapay Sinir Ağlarının Temel Gösterim Modeli .....	17
Şekil 4 RNN Modeli .....	19
Şekil 5 K-NN Hata Oranı Ve Komşu Sayısı Sonucu.....	23
Şekil 6 K-NN Tüm Etiketler İçin Başarı Sonuçları .....	24
Şekil 7 Karar Ağacı Algoritması Random_state Parametre Seçim Sonuçları .....	25
Şekil 8 Karar Ağacı Algoritması İçin Tüm Etiketler İçin Başarı Sonuçları .....	26
Şekil 9 Rastgele Orman Algoritması Max_depth Parametre Seçim Sonuçları.....	28
Şekil 10 RF Algoritması Tüm Etiketler İçin Başarı Sonuçları .....	28
Şekil 12 LGBMClassifier İçin Tüm Etiketlerin Başarı Sonuçları .....	32
Şekil 13 BaggingClassifier İçin Tüm Etiketler İçin Başarı Sonuçları .....	35
Şekil 14 CNN Model Özeti.....	37
Şekil 15 CNN İçin Tüm Etiketlerin Başarı Sonuçları.....	38
Şekil 16 RNN Model Özeti.....	40
Şekil 17 RNN İçin Tüm Etiketler Başarı Sonuçları.....	41
Şekil 18 Topluluk Öğrenmesi İçin Tüm Etiketlerin Başarı Sonuçları .....	43

## I. GİRİŞ

Çağdaş toplumda akıllı telefonların her yerde bulunması, bireylerin günlük rutinlerinin ayrılmaz bir parçası haline gelmiş; bilgi alma, eğlence tüketimi ve sosyal etkileşim gibi çok çeşitli amaçlara hizmet etmektedir. Ancak akıllı telefonlar, özellikle Etkinlik Tanıma (AR) gibi temel teknolojilerle ilgili değerli araştırmalar için de bir platform sunuyor. AR, sağlık verilerinin izlenmesi, bağlamsal mobil uygulama erişimi, Küresel Konumlandırma Sistemi (GPS) takibi, ev otomasyonu ve diğer işlevler gibi özellikleri kapsar. Bu çalışma, akıllı telefon tabanlı etkinlik tanıma sistemlerinin alanını araştırıyor ve bunların yenilikçi akıllı uygulamaları geliştirme potansiyelini kabul etmektedir.

Akıllı cihazların günlük hayata gelişen entegrasyonu, ortam zekasının bir tezahürüdür; burada bu cihazlar, bireylerin günlük aktivitelerini sorunsuz bir şekilde takip ederek bilinçli karar almayı kolaylaştırır. Bu araştırma, akıllı teknoloji uygulamalarının kullanımı yoluyla insan faaliyetlerinin tanınmasını örnekleyen bir akıllı telefon uygulamasına odaklanmaktadır.

Aktivite tanıma, bir dizi kişisel gözleme ve çevresel ipuçlarına dayanarak insan hareketlerinin tanımlanmasını içerir. İvmeölçerler gibi eylemsizlik sensörleri bu amaç için kullanılır ve genellikle bazı akıllı cihazlara varsayılan olarak entegre edilir. Bu sensörler, donanım denetimli makine öğrenimi algoritmaları aracılığıyla eylemsiz çerçeve göstergelerini yakalayıp çeşitli fiziksel aktivitelerin (örneğin ayakta durma, yatma, yürüme) sınırlı hesaplama kaynaklarıyla sınıflandırılmasına olanak tanır. Akıllı telefon işlevselliğini ve çevre bilincini geliştirmede sensörlerin önemli rolünün altı çiziliyor. Hızdaki değişiklikleri ölçen ivmeölçerler cep telefonu üretiminde her yerde bulunur ve hareketteki ani değişiklikleri tespit edebilir. Yerçekimini kullanarak yönü belirleyen jiroskoplar, cihazın konumunu ve hizalamasını gösteren sinyalleri kaydederek davranışsal çıkarım için çeşitli veriler sunar.

Bu çalışma, bir akıllı telefonun ivmeölçer ve jiroskop sinyallerinden elde edilen verileri dört farklı makine öğrenme yöntemini kullanarak sınıflandırır: Lojistik

Regresyon, Destek Vektör Sınıflandırıcısı (SVC), Karar Ağacı ve Rastgele Orman ve sonuçların karşılaştırmalı analizi.



## II. LİTERATÜR TARAMASI

İnsan Aktivitesi Tanıma (HAR) alanındaki arařtırmaların giderek artan önemi, hızla gelişen akıllı sensör sistemleri ile birlikte öne çıkmaktadır (Shalaby vd., 2022). Bu durum özellikle, Nesnelerin İnterneti (IoT) uygulamalarında sensör ve iletişim teknolojilerinin kilit rol oynadığı bağlamda belirgin hale gelmektedir. HAR sistemleri, haptikler, giyilebilir sensörler (Bijalwan vd., 2021; Ferrari vd., 2022; Manjarres vd., 2022; Bhat & Khan, 2021; Bozkurt, 2021), görme-tabanlı sensörler/kameralar (Khan vd., 2022; Tasnim vd., 2021), sağlık sensörleri (Maitre vd., 2021) ve çevresel sensörler (Madokoro vd., 2021; Hwang vd., 2021; Ronald vd., 2021) gibi çeşitli sensör türlerinin kullanılmasıyla dikkat çekmektedir.

Giyilebilir sensörler, hafiflik (birkaç gram), küçük boyutlar (birkaç mm), kolay programlanabilirlik ve maliyet etkinliği gibi üçlü niteliklere sahiptir. Bu sensörler, kayışlar veya yapıştırıcılar kullanılarak incelenen insan aktivitelerinin doğasına bağlı olarak kolayca farklı anatomik bölgelere (örneğin kol, bel, omuz, bilek veya bacak) bağlanabilmektedir (Manjarres vd., 2022).

HAR'da yaygın olarak kullanılan ivmeölçer (İ), insan faaliyetleriyle ilgili ivme verilerini toplamak için yaygın olarak kullanılmaktadır (Yen vd., 2021; Alawneh vd., 2021). İvmeölçere ek olarak, jiroskop (J) ve manyetometre (M) sensörleri, belirli zamansal noktalardaki eylemleri izlemek için vücuda çeşitli şekillerde takılmıştır. Bu sensörlerin (İ, J, M) birleştirilmesi, insan faaliyetlerinin tanınmasına yönelik makine öğrenimi metodolojileri yoluyla analize uygun, belirgin bilgiler sağlamaktadır (Elsts ve McConville, 2021).

HAR sistemleri genellikle birden fazla sensöre (İ, J, M) sahip olmaları ve akıllı telefonlar gibi giyilebilir, faydacı bilgi işlem cihazlarına erişim sağlamaları nedeniyle pratik olarak kabul görmüştür, özellikle de hesaplama gücü ve depolama kapasitesi düşünüldüğünde uygunluğu kabul edilebilir seviyededir (Ghate ve C, 2021; Thakur ve Biswas, 2021).

Alanyazında HAR çalışmaları değerlendirildiğinde, genellikle ayakta durma, oturma ve yürüme gibi rutin günlük yaşam aktivitelerine odaklanmıştır.

HAR alıřmaları genellikle veri toplama, veri n iřleme, zellik ıkarma, zellik seimi, eęitim, performans deęerlendirmesi, sınıflandırma ve karar verme ařamalarını iermektedir.

Ham sensr verilerini doęrudan makine ęrenimi uygulamalarına entegre etmek, eřitli insan faaliyetlerini ayırt etmek iin gerekli bilgileri yakalamadaki zorluklar nedeniyle pratik deęildir. Bu nedenle, standart HAR alıřmaları, zaman serisi verilerini zetleyen zelliklere dnřtrmek iin bir zellik ıkarma ařamasını gerektirmektedir. zellikle, maksimum, minimum, medyan, ortalama, tepeden tepeye deęer, standart sapma, sıfır geiř sayısı, arpıklık, basıklık ve sinyal entropisi gibi frekans ve zaman alanı zellikleri, ham sensr verilerinden ıkarılmaktadır. Bu ařama, sistem performansının geliřtirilmesinde nemli bir rol oynamaktadır (Maitre vd., 2021; Yen vd., 2021; Thakur ve Biswas, 2021).

HAR modelleri genellikle konuya zel (kiřiselleřtirilmiř) ve konular arası (genelleřtirilmiř) modeller olarak sınıflandırılabilir. İlk model, yalnızca tek bir kiřiden gelen verileri kullanarak eęitim ve test iin benzersiz hareket zelliklerini dikkate almaktadır. Dięer taraftan, konular arası modeller birden fazla kiřiden gelen verileri kullanır ve geniř veri kmelerinden yararlanma avantajları sunmaktadır. Bu modellerin seimi, kiřiselleřtirilmiř sınıflandırıcı geliřtirmek veya genelleřtirilmiř bir sınıflandırıcı kullanmak iin uygundur.

Chernbumroong ve arkadařları (2011) tarafından gerekleřtirilen alıřmada, eřitli aktiviteleri kategorize etmek iin bileęe takılan ivmeler verilerinden elde edilen zaman ve frekans alanı zelliklerini kullanan bir alıřma yrtmřlerdir. alıřmada hem Yapay Sinir Aęı'nı (YSA) hem de Karar Aęacı algoritmasını kullandılar ve alıřma sonucunda Karar Aęacı'nın performans aısından YSA'dan daha iyi performans gsterdięini ortaya ıkarmıřlardır.

Scholl ve van Laerhoven (2012), bileęe takılan ivmeler verilerinden yola ıkarak ve sinyal iřleme tekniklerini kullanarak bireylerde sigara ime alıřkanlıklarını incelemiřlerdir. Yaptıkları alıřmada Gauss Sınıflandırıcı kullanarak %51,2 bařarı oranına ulařmıřlardır. Benzer şekilde bileęe takılan ivmeler sinyallerinden elde edilen veriler aracılıęı ile Nguyen ve ark. Gnlk aktiviteleri tespit etmeye alıřmıřlardır. Yapılan alıřmada tek ynl sensor bilgisinin aksine hem sol hem de saę bilekten alınan sensor verilerine odaklanarak eřitli makine ęrenimi

tekniklerinin kullanılmasını içermekte idi. Rastgele Orman yöntemiyle %91,2'lik bir başarı oranına ulaşılar.

Konak ve ark. (2016) Cep telefonlarından elde edilen ivmeölçer verilerinin kullanarak özellikle zaman ve frekans alanına odaklanmak sureti ile günlük aktiviteleri sınıflandırmışlardır. Elde ettikleri başarı değerlendirildiğinde koşma eyleminde %100, sigara içme eyleminde %98 başarı gösterirken merdiven çıkmada %64.44 başarı göstermişlerdir.

Mehrang ve ark. (2018) İvmeölçer verilerine ek olarak kalp atışı bilgilerini ekleyerek çalışma yürütmüşlerdir. Rastgele Ormanı temel alan sınıflandırma yöntemleri %89,4 başarı oranına ulaşmıştır.

Aynı yıl Hegde ve ark. (2018) bileğe takılan ivmeölçerlerden gelen verileri SmartStep sensörleriyle birleştirerek günlük yaşam aktivitelerini sınıflandırmaya çalıştı. Multinomial Lojistik Ayrımcılık Yöntemini kullanarak %94'lük etkileyici bir başarı oranına ulaşılar.

Kongsil ve ark. (2019) bileğe takılan cihazlardan türetilen hem ivmeölçer hem de açılma hız verilerini kullanan bir model olan S-PAR'ı tanıttı. Yaptıkları çalışmada S-PAR,  $88,62 \pm 11,71$ 'lik bir F-puanı elde etmiştir.

Makine Öğrenimi yöntemleri İnsan Aktivitesi Tanıma (HAR) uygulamaları bağlamında gelişmeye devam ediyor. Afzali Arani ve ark. (2021) bileğe takılan ivmeölçerlerden ve elektrokardiyogramlardan elde edilen bütünleşmiş ölçümler gerçekleştirmiş olup Rastgele Orman temelli yaklaşımları %94 F1 puanı elde etmişlerdir.

Derin Öğrenme (DL), bilgisayar biliminde simetriyi somutlaştıran ve özellikle aktivite sınıflandırması alanında etkileyici bir yol olarak öne çıkan bir teknoloji olarak dikkat çekmektedir. Günlük hareketlerin tanınması amacıyla sadece makine öğrenmesi değil ayrıca derin öğrenme yöntemleri de kullanılmaya başlanmıştır.

Zeng ve ark. (2018) tarafından CNN'e verilen ivmeölçer verileri SoftMax katmanıyla sınıflandırılmış ve çalışmaya konu olan Actitraker veri seti ile %96.8 başarı oranı elde edilmiştir.

Yao ve ark. (2017), öznitelik çıkarımı için evrimsel katmanlara sahip iki seviyeli ve SoftMax katmanına sahip bir mimari uygulamışlardır. Kullandıkları bu mimari %95 F1 puanı elde etmiştir.

Mekruksavanich ve Jitpattanukul (2021), UTwente veri seti üzerinde gerçekleştirdikleri çalışmada CNN-BiGRU modeli uygulamışlardır. Bu model %97 ortalama F1-scoru elde etmiştir.

Nunavath ve ark. (2021) sınıflandırma için yalnızca Tekrarlayan Sinir Ağlarına (RNN) dayalı bir model sunmuştur. Metodolojileri, 10 saniyelik kayan pencereler kullanan UCI HAR veri setinde temel aktiviteler için %98,75 ve spesifik aktiviteler için %96,52 doğrulukla dikkate değer bir performans sergilemiştir.

Tarasevičius ve Serackis (2020), Uzun-Kısa Süreli Bellek (LSTM) giriş bloklarını içeren bir metodoloji önerdiler. Bi-LSTM organize yöntemleri, yüzücülerin bileklerine takılan ivmeölçerlerden, jiroskoplardan ve manyetometrelerden elde edilen verileri kullanarak yüzme stillerini sınıflandırmak için tasarlandı. Sinyal özelliklerini girdi olarak kullanan bu model, %91,39 F1-Skoruna ulaşmıştır.

Mevcut alanyazın genel olarak değerlendirildiğinde derin öğrenme teknikleri kullanılarak HAR alanında sınıflandırmanın etkili oluşuşunu doğrulamaktadır (Alawneh vd., 2021; Ghate ve C, 2021; Buffelli ve Vandin, 2021; Alhersh vd., 2021; Irfan vd., 2021; Al-Wesabi vd., 2021; Chen vd., 2020; Mihoub, 2021; Hassan vd., 2020; Bijalwan vd., 2021; Hoai Thu & Han, 2021; Stuart & Manic, 2021).

### III. MAKİNE ÖĞRENMESİNE VE DERİN ÖĞRENMEYE GİRİŞ

İnsanın bilişsel becerisi, karmaşık olayları kavramak için karmaşık modeller oluşturma, bilgi edinme ve altta yatan mekanizmaları çözme için eleştirel analize olanak sağlama konusundaki benzersiz kapasitesi ile ayırt edilir. Bu modellerden elde edilen bilgiler, gelecekteki olaylara ilişkin tahminleri kolaylaştırarak operasyonel dinamikleri aydınlatan teorik çerçevelere katkıda bulunur. Giderek daha doğru hale gelen modellerin evrimi, olgunun doğasında bulunan gerçek özelliklere ilişkin anlayışımızı geliştirir ve olasılıksal modele dayalı bir yaklaşım kullanan yapay kopyaların yaratılmasıyla sonuçlanır.

Bu bilimsel yaklaşım, yapay sinir ağlarının (YSA) kavramsallaştırılması yoluyla yapay zeka alanında yankı bulmaktadır. Bu ağlar, genelleştirilmiş bir biçimde de olsa, insan beyninin bilişsel işlevlerini taklit eder. Bir YSA, kavramsal düzeyde biyolojik bir beyinde bulunan temel birimlere veya nöronlara benzerlik gösteren, yapay nöronlar olarak adlandırılan birbirine bağlı düğümlerden oluşur. YSA içindeki ara bağlantılar, model öğrenme aşamasında dinamik olarak ayarlanan, öğrenme süreci boyunca biyolojik bir sinir ağı içindeki bağlantıların organik oluşumunu ve modifikasyonunu yansıtan ilişkili ağırlıklara sahiptir.

#### A. Yapay Zekâ

Yapay zekâ (AI-Artificial Intelligence), insanlar tarafından etkili bir şekilde gerçekleştirilen işlemlerin çok daha etkin bir şekilde yapılmasını sağlamak amacıyla yapılan çalışmaların açıklamasında kullanılan bir terim olarak geçmektedir (Karaatlı, 2003: 10).

Yapay zekâ, insanlarda var olan düşünce ve özelliklerin kodlarla birlikte makinaya aktarır. Makinanın insana has bu özellikleri deneyimlemesi, öğrenmesi, analiz etmesi, geliştirme ve yeni girdilere uyum sağlaması açısından kendi kendine öğrenebilmesi ve insana benzeyen görevleri gerçekleştirebilmesini mümkün kılmaktadır. Geliştirilen teknoloji sayesinde, büyük verilerin makinalar tarafından işlenmesi, verileri tanınması ve belirli görevleri uygulaması eğitim işlemi gösterir. Yapay zekâ günümüzde oldukça güncel ve yaygın olarak kullanılmaktadır. Bu

cihazlara cep telefonları, ev aletleri, sürücüsüz araçlar vd. örnek olarak verilebilir. Yapay zekânın bir alt kümesi olarak makine öğrenmesi bulunmaktadır. Makine öğrenmesi ise istatistiksel ve matematiksel yöntemler veri kümelerinden çıkarımlar yapmaktadır. Makine öğreniminin bir alt kümesi derin öğrenmedir. Derin öğrenme algoritma temelini Yapay Sinir Ağı (YSA) oluşturur (Akpınar, 2019: 1).

## **B. Makine Öğrenmesi**

Veri, ham haliyle, belirli bir konu hakkında yorum ve değerlendirme yapılmasını sağlayan araştırma, tartışma ve bilgi sağlamadan elde edilen işlenmemiş bilgileri oluşturur. Makine öğrenimi (ML), doğruluğu kademeli olarak artırmak için algoritmaların ve verilerin yinelemeli olarak iyileştirilmesini vurgulayan, insan öğrenme süreçlerini taklit eden bir dizi öğrenme metodolojisini kapsar (Wang ve Summers, 2012).

Sinir ağı gelişiminin kökenleri, 1943'te beyin nöronlarının çalışma prensiplerini açıklamak için elektrik devrelerini kullanarak temel bir sinir ağı kuran Warren McCulloch ve Walter Pitts'e kadar uzanmaktadır (McCulloch ve Pitts, 1990). Donald Hebb, 1949'da iki sinirin eşzamanlı aktivasyonunun aralarındaki bağlantıyı güçlendirdiğini ve sinir yollarının tekrar tekrar kullanılmasının bu bağlantıları güçlendirdiğini öne sürdü (Haider, 2008). Alan Turing, 1950 yılında bir makinenin insan benzeri davranışlar sergileyip sergilemediğini ve insandan ayırt edilemeyecek tepkiler verip vermediğini değerlendiren Turing testini başlattı (Shieber, 1994).

"Makine öğrenimi" terimi ilk kez 1952'de Arthur Samuel tarafından icat edildi ve genellikle yapay zekânın (AI) babası olarak anıldı (Samuel, 1953). Samuel'in makine öğrenimine ilk atılımı, bilgisayarın performansını yinelemeli olarak iyileştirmeyi, geçmiş hataları düzeltmeyi ve veriye dayalı içgörüler biriktirmeyi amaçlayan bir dama oyunu programı geliştirmeyi içeriyordu. 1957'de Frank Rosenblatt, verilerden öğrenmeyi kolaylaştırmak ve parametreleri optimum çözümlere ulaşmak için ayarlamak ve sınırlı başarı ile önceki yöntemleri geride bırakmak için tasarlanmış bir makine öğrenme algoritması olan perceptron'u tasarladı. Daha sonra, 1959 yılında Widrow ve Hoff tarafından "Adaline" ve "Madaline" adlı modeller tanıtıldı ve Madaline, gerçek dünya sorunlarına uygulanan ilk sinir ağını oluşturdu.

Perceptron'un sınırlamaları, 1969'da Marvin Minsky ve Seymour Papert tarafından "Perceptrons" adlı kitaplarında vurgulandı ve bu, onun basit bir XOR fonksiyonunu

ve bazı sınıflandırma problemlerini çözme konusundaki yetersizliğini ortaya koydu. Buna rağmen, çok katmanlı algılayıcıların bu tür zorlukların üstesinden gelme potansiyelini fark ettiler, ancak çok katmanlı algılayıcılar için eğitim algoritmalarının yokluğu 1981 yılına kadar makine öğrenimi araştırmalarında bir yavaşlamaya yol açtı (Marvin Minsky, 1988).

Mali kısıtlamalar 1980'lere kadar yapay sinir ağı (YSA) araştırmalarını engelledi, ancak 1982'deki Beşinci Nesil Bilgisayar Sistemleri projesi ilgiyi yeniden canlandırdı ve YSA araştırmalarına kaynak ayırdı. Bilgisayar için Sinir Ağları toplantıları 1985'te başladı ve Amerikan Fizik Enstitüsü'nün yıllık fikstürü haline geldi. Yann LeCun'un 1998'de belge tanıma için Uygulamalı Gradyan Tabanlı öğrenme hakkındaki yayını bu alanda bir dönüm noktası oldu (Lecun vd., 1998). Yeni metodolojiler de dahil olmak üzere makine öğrenimi üzerine devam eden çalışmalar çağdaş araştırmalarda da devam etmektedir (Kaya ve Kuncan, 2022; Tai vd., 2023).

## **1. Makine Öğrenmesi ve Yöntemleri**

### **a. Denetimli öğrenme**

Denetimli öğrenme, modelin etiketli veri kümeleri üzerinde eğitime tabi tutulduğu bir makine öğrenimi algoritmaları kategorisini oluşturur. Bu paradigma, sınıflandırma ve regresyon gibi görevlerde uygulama alanı bulur. Sınıflandırma çabalarında temel amaç, girdi verilerinin sınıfını veya kategorisini, ayırt edici özelliklerine bağlı olarak tahmin etmeyi gerektirir. Örnekleme gerekirse, denetimli bir öğrenme algoritması, her bir görüntünün ilgili sınıfla uygun şekilde etiketlendiği kedi ve köpek görüntülerinden oluşan bir veri kümesine maruz bırakılabilir. Bu eğitim süreci sayesinde algoritma, kediler ve köpekler arasındaki ayırt edici özellikleri ayırt etme kapasitesi kazanır ve ardından yeni görüntüleri uygun kategorilere sınıflandırabilir. Regresyon görevleri bağlamında genel amaç, girdi özelliklerine dayalı sürekli bir çıktı değerinin tahminidir.

### **b. Denetimsiz öğrenme**

Denetimsiz makine öğrenimi, yapay zeka alanında, açık bir rehberlik veya etiketli çıktı olmadan veri kümelerinin araştırılmasını ve analizini içeren bir paradigmadır. Modelin, sonuçları bilinen etiketli veriler üzerinde eğitildiği denetimli öğrenmenin

aksine, denetimsiz öğrenme, bilgi içindeki kalıpları, yapıları ve ilişkileri ayırt etmeye çalışarak etiketlenmemiş veriler üzerinde çalışır (Alpaydın, 2010:11).

Denetimsiz öğrenmenin temel amacı, genellikle kümeleme veya boyutluluk azaltma gibi teknikler yoluyla, veriler içindeki doğal yapıları veya gruplamaları ortaya çıkarmaktır. Kümeleme algoritmaları, verileri benzerliklere dayalı olarak gruplara ayırmayı amaçlarken, boyutsallık azaltma yöntemleri, temel özellikleri yakalayıp karmaşıklığını azaltarak veri kümesini basitleştirmeye çalışır (Aydın ve Özkul, 2015:38).

Denetimsiz öğrenmedeki yaygın yaklaşımlar arasında hiyerarşik kümeleme, k-ortalama kümeleme ve temel bileşen analizi yer alır. Bu yöntemler, önceden tanımlanmış etiketlerin yokluğunda modelin temeldeki yapıları, ilişkileri veya gizli özellikleri özerk bir şekilde tanımlamasına olanak tanır.

Denetimsiz öğrenmenin uygulamaları çeşitlidir ve anormallik tespiti, keşfedici veri analizi ve veri sıkıştırma gibi alanları içerir. Büyük veri kümeleri içindeki gizli kalıpların ortaya çıkarılmasında çok önemli bir rol oynar ve manuel incelemeyle hemen fark edilemeyecek değerli bilgiler sunar. Dolayısıyla denetimsiz öğrenme, etiketlenmemiş veri kümelerinde gömülü olan içsel yapıları ve bilgileri ortaya çıkarmada güçlü bir araç olarak hizmet eder ve karmaşık veri alanlarının kapsamlı bir şekilde anlaşılmasına katkıda bulunur.

### **c. Yarı denetimli öğrenme**

Sınırlı sayıda işlenmiş veri kullanılarak önemli miktarda ham veri için tahminlerin yapıldığı bir makine öğrenimi yaklaşımıdır. Bu öğrenme çerçevesinde, verilerden anlamlı bilgiler çıkarmak için sınıflandırma prosedürleri kullanılır. Yarı denetimli öğrenme ile denetimli muadili arasındaki temel ayrım, etiketli veri kümelerinin mevcudiyetinde yatmaktadır; yarı denetimli öğrenme, yarı denetimli öğrenmenin önemli ölçüde daha küçük bir etiketli veri oranıyla çalışmaktadır (Kızılkaya ve Oğuzlar, 2018: 92).

### **d. Takviyeli öğrenme**

Karar verme yeteneklerini özerk bir şekilde optimize ederek bir ortam içindeki başlangıç durumundan terminal durumuna geçme hedefiyle karakterize edilir. Bu yöntem, temsilciye etkili problem çözme için en uygun hareket tarzını ayırt etme yeteneği ile donatır ve son noktaya ulaşmadaki verimliliği vurgular. Temel prensip,

temsilciye etkili problem çözümüne katkıda bulunacak mantıklı kararların nasıl alınacağı konusunda talimat verilmesini içerir (Tan ve Karaköse, 2022: 249).

## 2. Makine Öğrenmesi Algoritmaları

### a. K-En Yakın komşu algoritması

K-En Yakın Komşu (KNN) algoritması, hem sınıflandırma hem de regresyon analizlerine uygulanabilen denetimli bir öğrenme metodolojisi olarak duruyor. KNN çerçevesinde, bilinmeyen sınıfa ait verilerle karşılaşıldığında, bunu eğitim setindeki diğer veri noktalarıyla karşılaştırmak için bir mesafe ölçümü kullanılır. Sınıflandırma süreci, hesaplanan uzaklık ölçümüne dayalı olarak sınıflandırılmamış veriler için en uygun sınıfın belirlenmesini içerir. KNN algoritmasının kritik bir yönü, sınıflandırma sürecinde dikkate alınan en yakın komşuların sayısını temsil eden "k" hiperparametresinin belirlenmesidir. Optimum "k" değerinin seçimi veri setinin özelliklerine bağlı olup,  $k=1$ 'den toplam gözlem sayısına "n" kadar bir aralık esas alınarak sınıflar atanabilmektedir (Dilki ve Deniz Başar, 2020: 227).

KNN algoritmasının hesaplama verimliliğinin optimalin altında olduğu belirtilmektedir, çünkü her numunenin ayrı ayrı taranmasını gerektirir ve sınıflandırma süreçlerinin uzamasına neden olur (Khan vd., 2002: 517). Temel olarak KNN algoritması, benzer noktaların veya değişkenlerin önemli bir kısmının aynı sınıfa ait olması gerektiğini varsayar. Bu bağlamda bilinmeyen bir sınıfa sahip verinin yakınlığı, önceden tanımlanmış bir mesafe ölçümü aracılığıyla belirlenir (Hu vd., 2016: 2).

KNN algoritmasında mesafelerin hesaplanmasında çeşitli mesafe ölçüm birimleri kullanılmaktadır. İki nokta arasındaki direkt çizgi mesafesiyle karakterize edilen Öklid mesafesi, karşılık gelen değişkenler arasındaki farkların karelerinin toplamının matematiksel olarak karekökü olarak ifade edilen yaygın bir seçimdir (Atbaş, 2008: 13). Değişkenler arasındaki mutlak farkların toplamı olarak ifade edilen Manhattan mesafesi, iki nokta arasındaki dik doğru parçaları boyunca kat edilen mesafeyi ifade etmektedir (Taşçı ve Onan, 2016: 3). Hem Öklid hem de Manhattan ölçümlerini kapsayan genelleştirilmiş bir form olan Minkowski mesafesi,  $\lambda$ 'nın 1'den büyük veya ona eşit olduğu " $\lambda$ " kuvvetine yükseltilmiş mutlak farkların toplamı olarak temsil edilir (Kresse ve Danko, 2012: 118).

### b. Destek vektör makineleri

Destek Vektör Makineleri (SVM), Küçüksille ve Ateş (2016: 2) tarafından belgelendiği gibi Vapnik tarafından tanıtılan bir öğrenme metodolojisini temsil etmektedir. Çok yönlülüğü ile tanınan DVM, hem sınıflandırma hem de regresyon analizlerinde yaygın olarak kullanılmaktadır, ancak denetimli öğrenme alanındaki sınıflandırma görevlerinde önemi özellikle dikkat çekicidir (Metlek ve Kayaalp, 2020: 21). SVM, doğrusal ayırmaya uygun iki sınıflı veri kümelerinin sınıflandırılmasında yerini bulmaktadır (Kartal, 2020: 1407).

Destek vektör makinelerinin uygulanabilirliği, yüz algılama, metin sınıflandırma, görüntü sınıflandırma, el yazısı tanımanın yanı sıra jeoloji ve çevre bilimi uygulamalarını kapsayan ancak bunlarla sınırlı olmayan çeşitli örüntü tanıma alanlarına uzanır (Metlek ve Kayaalp, 2020: 22).

Temel olarak destek vektör makineleri, hem sınıflandırma hem de regresyon metodolojileri için gerekli bir süreç olan belirli bir eğitim veri seti için girdi-çıkı haritalama fonksiyonunu aydınlatır (Ecer, 2013c: 86; Kara, 2019: 61). Bu, SVM'nin veri kümeleri içindeki karmaşık ilişkileri açığa çıkarmadaki önemini altını çizerek, onu özellikle ikili sınıflandırma ve örüntü tanımanın öğrenme sürecinin ayrılmaz bileşenleri olduğu çeşitli uygulamalarda değerli bir araç haline getirir.

### **c. Rastgele orman sınıflandırıcısı**

Rastgele Orman Sınıflandırıcısı, makine öğrenimi alanında etkili olduğu kanıtlanmış, sağlam ve çok yönlü bir topluluk öğrenme algoritmasıdır. Leo Breiman tarafından 2001 yılında tanıtılan bu algoritma, tahmin doğruluğunu artırma ve bireysel modellerle ilişkili aşırı uyum sorunlarını azaltma konusundaki etkinlikleriyle bilinen topluluk yöntemleri kategorisine girmektedir (Taşçı ve Onan, 2016:3).

Rastgele Orman Sınıflandırıcısı özünde, genellikle karar ağaçları olarak adlandırılan birden fazla bireysel modelin tahminlerini birleştiren bir topluluk öğrenme çerçevesi içinde çalışır. Bu karar ağaçları toplu olarak bir "orman" oluşturur ve bunların kombinasyonu daha sağlam ve doğru bir genel tahmine yol açar (Kresse ve Danko, 2012: 118).

Rastgele Orman içindeki her karar ağacı, eğitim verilerinin bir alt kümesine ve rastgele seçilmiş özellikler temel alınarak oluşturulur. Bu kasıtlı rastgelelik, kurucu ağaçlar arasında çeşitlilik sağlar, böylece aşırı uyumu önler ve modelin genelleme yeteneklerini geliştirir.

Eđitim s¼reci, eđitim verilerinin farklı alt k¼melerini kullanarak ¼oklu karar ađaçlarının yinelemeli olarak oluřturulmasını i¼erir. Her ađaç bađımsız olarak geliřtirilir ve ađaçtaki her d¼ğ¼m¼n oluřturulması s¼recinde, optimum b¼l¼nmeyi belirlemek i¼in rastgele bir ¼zellik alt k¼mesi dikkate alınır. ¼zellik se¼imi ve veri ¼rneklemedeki bu ¼eřitlilik, genel modelin g¼c¼ne katkıda bulunur.

Tahminlerde bulunmaya gelince, Rastgele Ormandaki her ađaç bađımsız olarak tahminini sađlar ve nihai ¼ıktı, ¼ođunluk oylama mekanizması aracılıđıyla belirlenir. Sınıflandırma g¼revleri i¼in, kurucu ađaçlar arasında en fazla oyu alan sınıf, son tahmin olarak se¼ilir. Regresyon g¼revlerinde tahmin edilen deđerlerin ortalaması dikkate alınır.

Rastgele Orman Sınıflandırıcısı, y¼ksek dođruluk, ařırı uyarlamaya karřı dayanıklılık ve hem sınıflandırma hem de regresyon g¼revlerini etkili bir Őekilde ele alma yeteneđi dahil olmak üzere ¼eřitli avantajlar sunar. ¼ok sayıda ¼zelliđe sahip b¼y¼k ve karmařık veri k¼meleri i¼in ¼zellikle uygundur.

Rastgele Ormanlar uyarlanabilirlikleri ve sađlımlıkları nedeniyle finans, sađlık hizmetleri ve biyoinformatik gibi ¼eřitli alanlarda uygulama alanı bulmaktadır. Yorumlanabilirliđin, ¼zelliđin ¼neminin ve dođru tahminlerin ¼ok ¼nemli olduđu senaryolarda bařarılı olurlar.

Rastgele Orman Sınıflandırıcı, ¼eřitli makine ¼đrenimi g¼revlerinde dođru ve sađlam tahminler elde etmek i¼in ¼oklu karar ađaçlarının kolektif bilgeliđinden yararlanan g¼çlü bir topluluk ¼đrenme algoritması olarak duruyor.

#### **d. Karar ađacı algoritması**

Karar Ađacı algoritması, hem sınıflandırma hem de regresyon g¼revlerinde yaygın olarak kullanılan ¼ok y¼nl¼ ve yorumlanabilir bir makine ¼đrenme y¼ntemidir. Her i¼ d¼đ¼m¼n belirli bir ¼zelliđe dayalı bir kararı temsil ettiđi ve her yaprak d¼đ¼m¼n bir sınıf etiketine veya tahmin edilen bir deđere karřılık geldiđi ađaç benzeri bir model oluřturur. Algoritma, verileri en bilgilendirici ¼zelliklere dayalı olarak yinelemeli olarak b¼l¼mlere ayırır ve bu da onu tahmine dayalı modelleme i¼in g¼çlü bir ara¼ haline getirir (Kara, 2019: 71; Rostami vd., 2015: 164).

Karar Ađacı algoritmasının temelinde, genellikle karar verme s¼re¼lerinde kullanılan bilgi kazanımı kavramı yer alır. Bilgi kazancı, bir veri k¼mesindeki safsızlık veya d¼zensizliđin bir ¼l¼s¼ olan entropi kullanılarak hesaplanır. Entropi, bir dizi veri

noktasıyla ilişkili belirsizliği ölçer ve veri kümesini bölmek için en ayırt edici özellikleri belirlemek için kullanılır (Ramasubramanian ve Singh, 2017: 297).

Algoritma, her karar düğümünde bölme için en uygun özelliği belirlemek üzere yinelemeli bir süreç kullanır. Bilgi kazanımını en üst düzeye çıkaran veya entropiyi en aza indiren özellik seçilir ve veri noktalarının homojen alt kümelere etkili bir şekilde ayrılmasını kolaylaştırır. Bu süreç, karar düğümlerinin oluşumuna yol açan hiyerarşik bir yapı oluşturmak için tekrarlanarak uygulanır (Tsai ve Wang, 2009: 60).

Entropiye ek olarak kararları bölmek için yaygın olarak kullanılan bir başka kriter de Gini safsızlığıdır. Gini safsızlığı, veri kümesinde rastgele seçilen bir ögenin yanlış sınıflandırılma olasılığını ölçer ve ağaç oluşturma işlemi sırasında en aza indirilir. Karar Ağaçları, safsızlık ölçüsü olarak bilgi kazancı/entropi veya Gini safsızlığı kullanılarak oluşturulabilir (Lavanya ve Rani, 2011: 2).

Aşırı uyumdan kaçınmak için Karar Ağaçları sıklıkla bir budama sürecinden geçer. Budama, eğitim verilerine özgü gürültüyü veya karmaşıklıkları yakalayabilen ancak yeni, görünmeyen verilere iyi bir şekilde genelleştirilemeyen ağacın belirli dallarının kaldırılmasını içerir. Bu, daha sağlam ve genelleştirilmiş bir model elde edilmesine yardımcı olur.

Kullanım durumlarına ve bölme kriterlerine bağlı olarak farklı Karar Ağaçları türleri vardır. Dikkate değer iki tanesi:

CART (Sınıflandırma ve Regresyon Ağaçları): Safsızlık ölçüleri olarak Gini safsızlığı veya ortalama kare hatası kullanılarak öncelikle sınıflandırma ve regresyon görevleri için kullanılır (Dunham, 2003: 126).

ID3 (Yinelemeli Dichotomiser 3): Tipik olarak sınıflandırma görevleri için kullanılır ve karar verme sürecinde bilgi kazanımı ve entropi kullanılır (Loh, 2011: 14).

Karar Ağaçları finans, sağlık hizmetleri ve doğal dil işleme gibi çeşitli alanlarda uygulamalar bulur. Yorumlanabilir ve şeffaf karar kuralları sağlama yetenekleri, onları özellikle model yorumlanabilirliğinin çok önemli olduğu senaryolarda değerli kılmaktadır.

Karar Ağaçları genellikle Rastgele Ormanlar ve Gradyan Arttırma gibi topluluk yöntemlerinde kullanılır. Bu yöntemler, tahmin doğruluğunu artırmak ve bireysel

ağaç sınırlamalarının üstesinden gelmek için birden fazla Karar Ağacının güçlü yönlerinden yararlanır.

Karar Ağacı algoritması, şeffaflığı, yorumlanabilirliği ve karmaşık karar sınırlarını yakalamadaki etkinliği ile karakterize edilen, makine öğreniminde temel bir yöntemdir. Entropi, bilgi kazanımı ve Gini safsızlığı gibi bilimsel temelleri, çeşitli uygulamalarda tahmine dayalı modelleme konusundaki becerisine katkıda bulunur.

### **C. Derin Öğrenme**

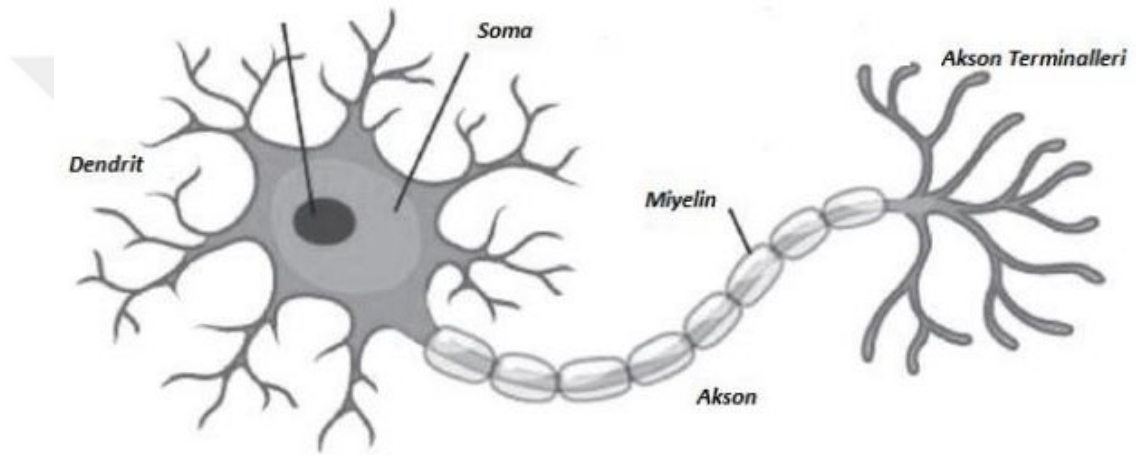
Derin öğrenme, insan beynine özgü bilişsel süreçleri taklit etmek için tasarlanmış karmaşık, çok katmanlı bir öğrenme paradigması oluşturur. Bu modelleme yaklaşımı, girdi verileriyle ilişkili ağırlıkları ve önyargıları birleştirerek sinir işlevlerini kopyalamayı amaçlamaktadır. Niteliklerin sonuçta ortaya çıkan birleşimi, veri içindeki nesnelere ustaca ayırt etmek ve sınıflandırmak için işbirliği içinde çalışır. Derin öğrenmenin bir tezahürü olan derin sinir ağları, birbirine bağlı çok sayıda düğüm katmanından oluşur. Bir öncekinin üzerine eklenen her ek katman, tahmin yeteneklerini ve kategorizasyon zekasını geliştirmeye ve optimize etmeye hizmet eder. Derin öğrenmenin bilgisayarlı görme disiplini üzerindeki derin etkisi, görüntü temsillerini öğrenmek ve göze çarpan özellikleri çıkarmak için güçlü metodolojiler sağlamasında açıkça görülmektedir.

Tekrarlayan sinir ağlarının başlangıcı, tekrarlayan sinir ağlarını ortaya çıkaran TSA'nın (Geçici Öz-Dikkat) tanıtılmasıyla 1982'de John Hopfield'a atfedilebilir (Hopfield, 1982). Bu alanda çok önemli bir ilerleme, 1997 yılında Schmidhuber ve Hochreiter'in, TSA içindeki işlevsellik ve işlem hızını önemli ölçüde artırmasıyla tanınan bir tür tekrarlayan sinir ağı olan Uzun Kısa Süreli Belleği (LSTM) önerdiğinde gerçekleşti (Hochreiter ve Schmidhuber, 1997). LSTM'nin kullanımı çeşitli araştırma çabalarına nüfuz etmiştir (Hochreiter ve Schmidhuber, 1997; Kaya vd., 2022; Kuncan vd., 2022).

Alex Krizhevsky, Geoffrey Hinton ve Ilya Sutskever tarafından 2012'de geliştirilen ve geniş ImageNet veri kümesinden yararlanan AlexNet modeliyle örneklendirilen Evrişimli Sinir Ağlarının (CNN'ler) ortaya çıkışıyla daha fazla yenilik ortaya çıktı (Krizhevsky vd., 2012). Günümüzde derin öğrenme, tıbbi görüntü analizi, robotik ve otonom araçlar gibi görüntü işleme alanları başta olmak üzere çeşitli alanlarda uygulama alanı bulmuştur (Köse vd., 2019; Ataş vd., 2022; Altuncu vd., 2023).

## 1.Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyninin doğasında bulunan öğrenme özelliklerine benzer şekilde keşif, türetme ve yaratma gibi bilişsel yetenekleri taklit etmek için tasarlanmış bilgisayar tabanlı sistemleri temsil etmektedir (Tiken, 2015: 3). YSA'nın temel konsepti, ilk olarak Negnevitsky (2005: 30) ve Karakoyun (2018: 27) tarafından Şekil 1'de görsel bir temsille tanıtılan biyolojik sinir hücrelerinden ilham almaktadır.

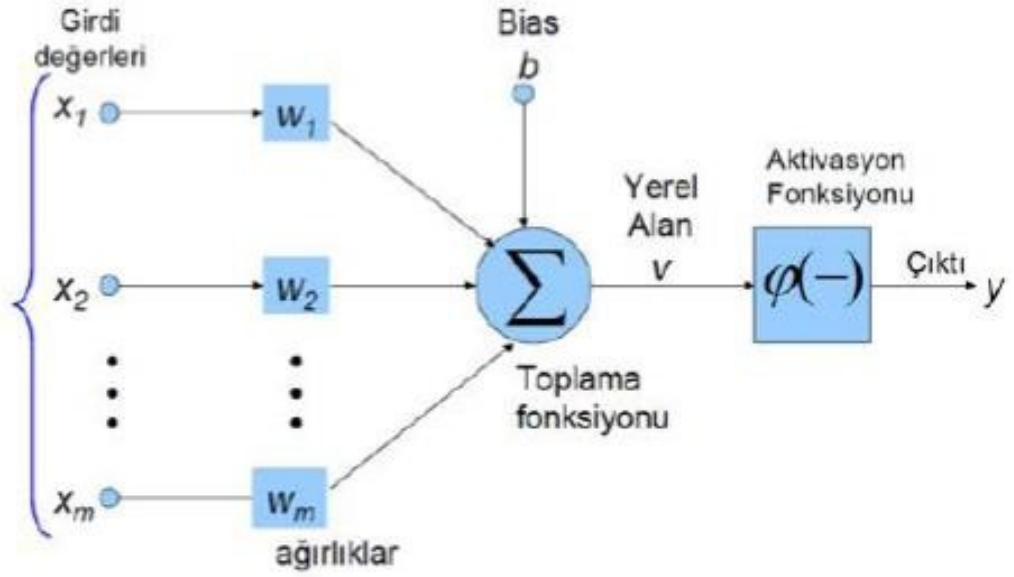


Şekil 1 Sinir Hücresinin Modellenmesi

**Kaynak:** (Negnevitsky, 2005: 30; Karakoyun, 2018: 27).

Bir nöron veya sinir hücresi, hem elektriksel hem de kimyasal sinyaller yoluyla bilgiyi alan, işleyen ve ileten temel birim olarak hizmet eder. Elektriksel olarak uyarılabilen bir varlık olarak işlev gören nöron, beyindeki karmaşık ağların merkezinde yer alır (Seymour, 1997: 5). Nöral aktiviteler için anahtar bileşenler arasında dendritler, hücre gövdeleri ve aksonlar yer alır; dendritler sinyalleri hücre çekirdeğine iletir, hücre gövdesi sinyalleri birleştirir ve akson bilginin sonraki sinir hücrelerine iletilmesini kolaylaştırır.


Biyolojik sinir sisteminden yapay sinir ağına geçiş bir dönüşüm sürecini içermektedir. Bu metamorfoz, nöron süreçlerinden, dendritik birikim fonksiyonlarından, hücre gövdesi aktivasyon fonksiyonlarından, akson çıkışlarından sinaps ağırlıklarına geçişi gösteren Şekil 2'de tasvir edilmiştir (Şeker, 2017: 4).



Şekil 2 YSA Yapısı

**Kaynak:** (Şeker, 2017: 4).

YSA, Şekil 3'teki Yapay Sinir Ağlarının Temel Temsil Modelinde gösterildiği gibi düğümlerden oluşan bir ağ yapısı oluşturularak birbirine bağlı ve paralel bir şekilde çalışır (Tiken, 2015: 3).



Şekil 3 Yapay Sinir Ağlarının Temel Gösterim Modeli

**Kaynak:** (Tiken, 2015: 3).

YSA' nın temel görevi, girdilere karşılık gelen çıktıların üretilmesinde yatmaktadır. Bu, ilgili örneklerin ağ üzerinden çalıştırılmasını, genellemeyi kolaylaştırmayı ve örneklenmiş girdilere benzer çıktılar üretmeyi içermektedir (Özkaynak, 2013: 5).

YSA içindeki hesaplama, sağlam bir paralel dağıtılmış yapı ve öğrenme ve genelleme yeteneği ile karakterize edilir. Genelleştirme sırasında ağ, öğrenme aşamasında karşılaşılmayan veriler için mantıksal çıktılar üretmeye çalışır.

Yapay Sinir Ağları, doğrusal olmama, öğrenme, adaptasyon, kanıta dayalı çıktı, genelleme, hata toleransı, Çok Büyük Ölçekli Entegrasyon (VLSI) uygulanabilirliği, analiz ve tasarım birliği ve nörobiyolojik benzerlik gibi birçok temel özellik ile ayırt edilmektedir (Doğan, 2003: 7). Bu özellikler toplu olarak YSA'yı karmaşık sorun yapılarının analizi için güçlendirir ve çeşitli alanlardaki çok yönlülüğünü ve faydasını sergiler.

#### **a. Tekrarlayan sinir ağları (RNN)**

Tekrarlayan Sinir Ağları (RNN), sıralı bilgilerin kullanımıyla karakterize edilen bir yapay sinir ağları kategorisini temsil eder. Giriş ve çıkışların bağımsız olarak ele alındığı geleneksel sinir ağlarının aksine, RNN' ler, önceki çıkışlara bağlı olarak her bir öge için aynı işlemi bir sırayla yinelemeli olarak gerçekleştirerek "tekrarlayan" tanımını kazanırlar (Şeker, 2017: 13).

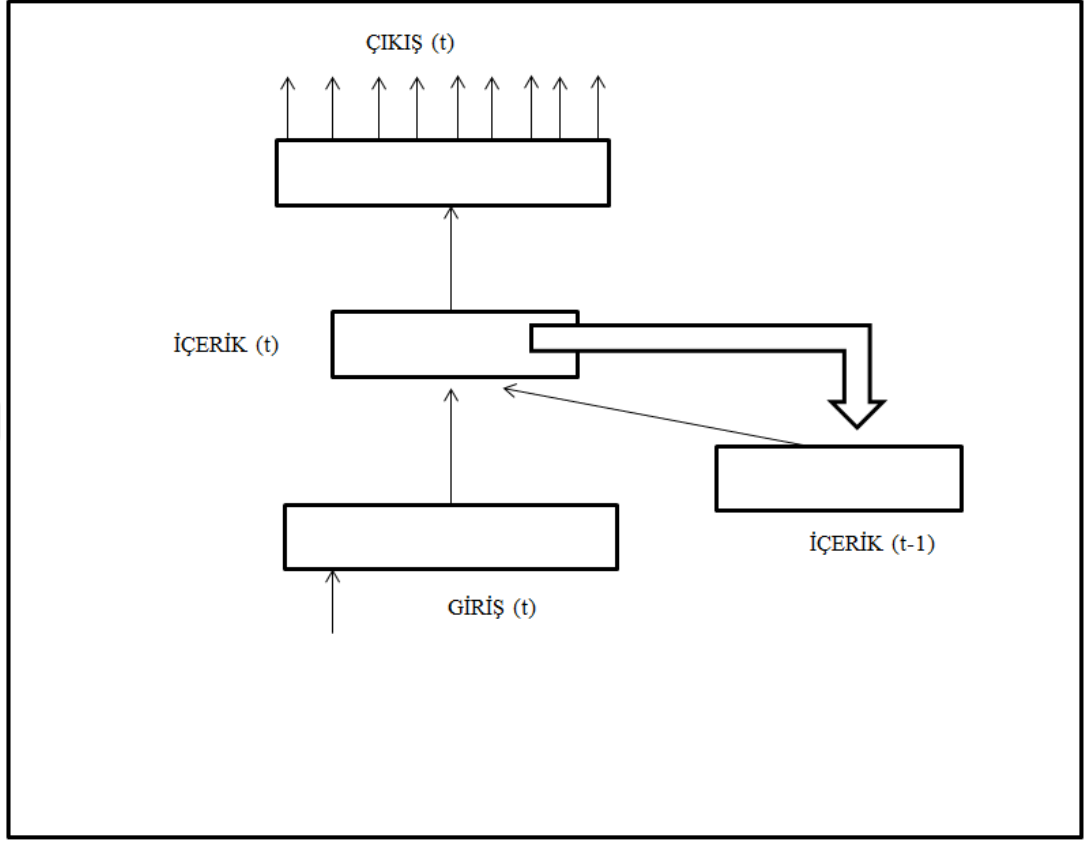
RNN' nin ayırt edici özelliği, birimler arasında yönlendirilmiş bir döngü aracılığıyla bağlantıların kurulmasında yatmaktadır. Rastgele girdi dizilerinin işlenmesinde etkili olan bu döngü, ağın dahili bir durum oluşturmasını sağlar ve böylece ona dinamik zamansal davranış gösterme kapasitesi kazandırır (Mikolov vd., 2010: 1045). Şekil 4, RNN Modelinin kavramsallaştırmasını göstermektedir.

Geleneksel sinir ağlarının aksine, RNN' ler sıralı ögeler arasındaki bağımlılıkları ele alma kapasitesi sergiler. Bu sıralı işleme yeteneği, RNN' leri özellikle doğal dil işleme, konuşma tanıma ve zaman serisi tahmini gibi zamansal dinamikleri ve bağlamları içeren görevlerde usta hale getirir.

Bununla birlikte, RNN' ler, kaybolan gradyan probleminden dolayı uzun menzilli bağımlılıkları yakalamada zorluklarla karşılaşmaktadır. Uzun Kısa Süreli Bellek (LSTM) ağları ve Geçitli Tekrarlayan Birimler (GRU) gibi sonraki gelişmeler, bu zorlukları hafifletmek ve RNN' lerin genişletilmiş diziler boyunca bilgileri yakalama ve saklama yeteneğini geliştirmek için uygulamaya konmuştur.

RNN' ler, bağlam ve zamansal bağımlılıkların anlaşılmasının çok önemli olduğu doğal dil işleme de dahil olmak üzere çeşitli alanlarda yaygın uygulamalar bulur.

Tekrarlanan yapıları, onları, tarihsel bağlamın mevcut bilgilerin yorumlanmasını önemli ölçüde etkilediği görevlere uygun hale getirir.



Şekil 4 RNN Modeli

**Kaynak:** (Mikolov vd., 2010: 1045)

Tekrarlayan Sinir Ağları, sıralı bilgileri etkili bir şekilde işlemek için tasarlanmış özel bir yapay sinir ağları sınıfını oluşturur. Tekrarlayan doğası, zamansal bağımlılıkların modellenmesini kolaylaştırır ve onları bağlam ve tarihsel sekansların anlaşılmasını gerektiren uygulamalarda etkili kılar. Devam eden araştırmalar ve gelişmeler, RNN'lerdeki uzun vadeli bağımlılıklarla ilişkili zorlukları çözmeye devam ediyor.

#### b. Evrimsel sinir ağları (CNN)

Görüntü tanıma alanında çığır açan bir derin öğrenme algoritması olarak selamlanan Evrimsel Sinir Ağları (CNN'ler), nesne algılama, yüz tanıma ve sahne tanımayı kapsayan, görüntüyle ilgili çeşitli görevlerde örnek performans sergilemiştir. Yann LeCun ve işbirlikçilerinin (LeCun vd., 1998) çalışmalarından yola çıkan CNN'ler,

derin öğrenmenin popülaritesindeki artışla desteklenen, bol miktarda veri kullanılabilirliği ile desteklenen ve en çok tercih edilen derin öğrenme metodolojilerinden biri olarak ortaya çıkarak ön plana çıkmıştır.

CNN'in temel mimarisi evrişimli, havuzlamalı ve tamamen bağlantılı katmanlardan oluşur. Evrişim katmanında, giriş görüntüsüne, kenarlar ve köşeler gibi göze çarpan özellikleri tespit etme konusunda usta filtreler uygulanır. Daha sonra havuzlama katmanı, alt örnekleme yoluyla özellik haritası boyutlarını azaltır. Kaskadını tamamlayan tamamen bağlı katman, giriş görüntüsünün sınıflandırılması için geleneksel bir sinir ağı kullanarak evrişim ve havuzlama katmanlarından gelen çıktıları özümser (LeCun vd., 2015).

CNN'lerin dikkate değer bir avantajı, açık özellik seçimi gerekliliğini ortadan kaldırarak özellikleri özerk bir şekilde öğrenme kapasitelerinde yatmaktadır. Bu özerk öğrenme, giriş görüntüsündeki desenleri filtre uygulaması yoluyla ayırt eden evrişim katmanına atfedilir. Evrişim katmanı, özellikle görüntü tanıma gibi bilgisayarla görme görevlerinde, giriş verilerinden anlamlı özelliklerin işlenmesinde ve çıkarılmasında çok önemli bir rol oynar. Evrişimsel katman, kenarlar, köşeler ve dokular da dahil olmak üzere ilgili desen ve özellikleri tanımak için eğitim sırasında dinamik olarak öğrenilen filtreleri veya çekirdekleri kullanır.

Evrişim katmanının önemi hiyerarşik özellik çıkarımı gerçekleştirme yeteneğinde yatmaktadır. Küçük pencereleri (filtreler veya çekirdekler) girdi boyunca kaydırarak ve öge bazında çarpma ve toplamları yürüterek bir çıktı özellik haritası oluşturur. Çeşitli filtrelerin girdiyle sinerjik bir kombinasyonu sayesinde katman, düşük seviyeli özelliklerden oluşan bir spektrumu tanımlamada yeterliliğe ulaşır ve karmaşık ve soyut özellikleri kapsüllemek için bunları kademeli olarak daha yüksek katmanlarda toplar.

CNN'ler, ImageNet gibi yarışmalarda özellikle görüntü sınıflandırmada üstün performanslarıyla ün kazandılar (Krizhevsky vd., 2012). CNN'lerin çok yönlülüğü görüntü merkezli alanların ötesine geçerek doğal dil işleme ve konuşma tanıma gibi alanlara da nüfuz ediyor. Hesaplama becerisinin ve veri erişilebilirliğinin sürekli olarak artması, gelecekte CNN'ler için yeni uygulamaların geliştirileceğinin habercisidir. Teknoloji ilerledikçe CNN'ler yenilik ve uygulanabilirliğin yeni boyutlarını başlatmaya hazırlanıyor.

Evriřimli Sinir Ağları, görüntüyle ilgili görevler için karmařık bir řekilde tasarlanmıř, derin öğrenme metodolojilerinde bir zirve noktası olarak duruyor. Hiyerarřik özellik çıkarımı ve otonom öğrenme yetenekleri, onları bilgisayarlı görme ve ötesinde, devam eden evrim ve çeřitlenmeye hazır bir yörüngeye sahip araçsal araçlar olarak işaretler.



## IV. UYGULAMA VE BULGULAR

Çalışmanın bu bölümünde; araştırmanın amacı, veri seti ve yöntem (metodoloji) ve son olarak bulgular yer almaktadır.

### A. Araştırmanın Amacı

Mevcut literatürün incelenmesi ve insan etkinliklerinin tanınması alanının araştırılması üzerine çok sayıda araştırma ortaya çıkmıştır. Bu araştırma bu soruları yanıtlamaya çalışarak araştırma alanının ilerlemesine katkıda bulunmayı amaçlamaktadır. Bu çalışmaya yön veren başlıca sorular şunlardır:

Çalışmada kullanılan extrasensory veri seti ile elde edilen verilerden insan hareketleri yapay zekâ teknikleri ile tespit edilebilir mi? Bireylerin hareketlerini tespit etmek için Yapay zekâ tekniklerinden hangisi en uygundur. Çalışma HAR' ın kapsamlı bir şekilde anlaşılmasını sağlamayı amaçlamaktadır.

### B. Veri Seti

Extrasensory veri seti, Vaizman vd. tarafından oluşturulan bir veri setidir. Bu veri seti, insanların günlük aktivitelerini ve durumlarını belirlemek amacıyla tasarlanmıştır. İnsan davranışlarını anlamak ve sınıflandırmak için makine öğrenimi ve aktivite tanıma modellerinin geliştirilmesinde kullanılmıştır (Vaizman vd., 2018 ).

Extrasensory veri seti, bir dizi sensör tarafından toplanan verilere dayanmaktadır. Bu sensörler arasında GPS, ivmeölçer, manyetometre, mikrofon ve ışık sensörü gibi çeşitli türler bulunmaktadır. Toplanan veriler, kullanıcıların hareketleri, etkileşimleri ve çevresel koşulları gibi çeşitli özellikleri içermektedir.

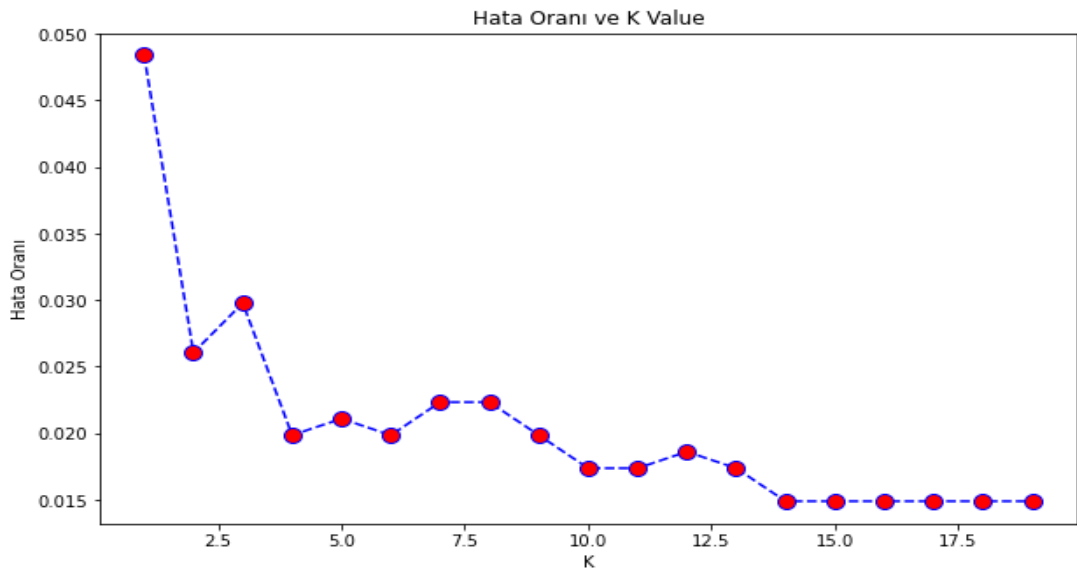
Veri seti, insanların yürüme, koşma, oturma, yemek yeme gibi aktivitelerini ve çevresel faktörlerin (örneğin, gün ışığı seviyesi) etkilerini içerir. Bu tür bir veri seti, aktivite tanıma, konum belirleme ve çevresel durum tahmini gibi uygulamalarda kullanılabilecek modellerin geliştirilmesine olanak sağlamak için tasarlanmıştır.

## C. Bulgular

Bu alt başlıkta, çalışmada kullanılan KNN, SVN, RF, NV, DT makine öğrenmesi ve CNN ve RNN derin öğrenme tekniklerinin sonuçları verilmiştir. Veri seti içerisinde çoklu etiket sınıflandırması kullanılmıştır. Bu nedenle çalışmada kullanılan sınıflandırma algoritmalarında elde edilen hata matrix'i klasik yöntemin dışında oluşturulan yeni bir formatta gerçekleştirilmiştir. Oluşturulan hata matrix'inde her sınıflandırma için değerlendirilen etiketin doğru sınıflandırılıp sınıflandırılmadığı nazara alınmıştır. Matrix içinde iki adet notasyon kullanılmıştır. Notasyon olarak SCS başarılı ve F ise başarısız sınıflandırmaları ifade etmektedir.

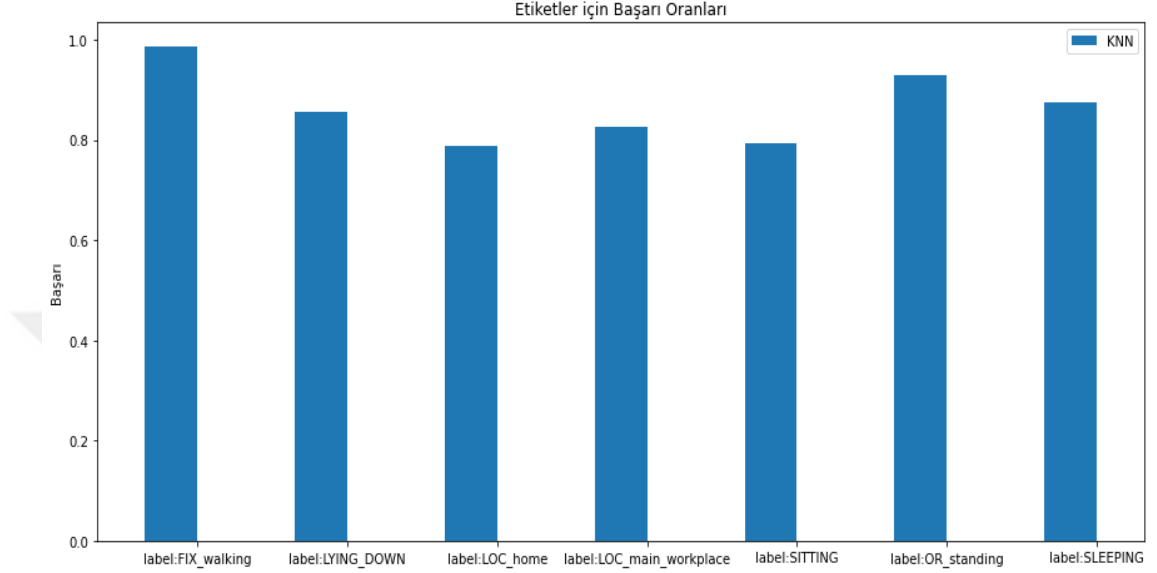
### 1. K-NN Analiz Sonuçları

K-NN tekniğinde alınan bir verinin komşularına göre yakınlığına bakılmaktadır. Komşu sayısının doğru olarak tespit edilmesi tekniğin başarısının en önemli faktörlerinden biridir. Veri setinde yapılan değerlendirmenin en iyi başarıyı elde etmesi amacıyla öncelikle rastgele bir sayı aralığında tekniğin başarısı kontrol edilmiştir. Deneme 100 adet komşu ile test edilmiştir. Gerçekleştirilen testin sonuçları değerlendirildiğinde 15-20 aralığındaki komşu değerinde en düşük hata oranı olduğu tespit edilmiştir. Şekil 5'te 1-20 aralığında komşu değeri seçimi gerçekleştirilmesi durumunda elde edilen hata oranı sonuçları gösterilmiştir. Elde edilen sonuçlara göre en uygun komşu değerinin 17 olduğu anlaşılmıştır.



Şekil 5 K-NN Hata Oranı Ve Komşu Sayısı Sonucu

K-NN tekniği ile tüm etiketler üzerinden gerçekleştirilen öğrenme süreci sonrası elde edilen sonuçlar Şekil 6’da verilmiştir. Elde edilen sonuçlar değerlendirildiğinde en yüksek başarının FIX\_walking etiketinde %97.76 ile elde edildiği anlaşılmaktadır. Değerlendirmeye tabi tutulan etiketler arasında en düşük başarı oranı %76.42 ile SITTING etiketinde tespit edilmiştir.



Şekil 6 K-NN Tüm Etiketler İçin Başarı Sonuçları

K-NN algoritması kullanılarak gerçekleştirilen sınıflandırma işleminin sonucunda her bir etiketin değerlendirmesi için aşağıda Çizelge 1’de hata matrix’i verilmiştir. Çizelgedan da anlaşılacağı üzere en başarılı sınıflandırma FIX\_walking (SCS = 794) etiketinde ile elde edilmiştir.

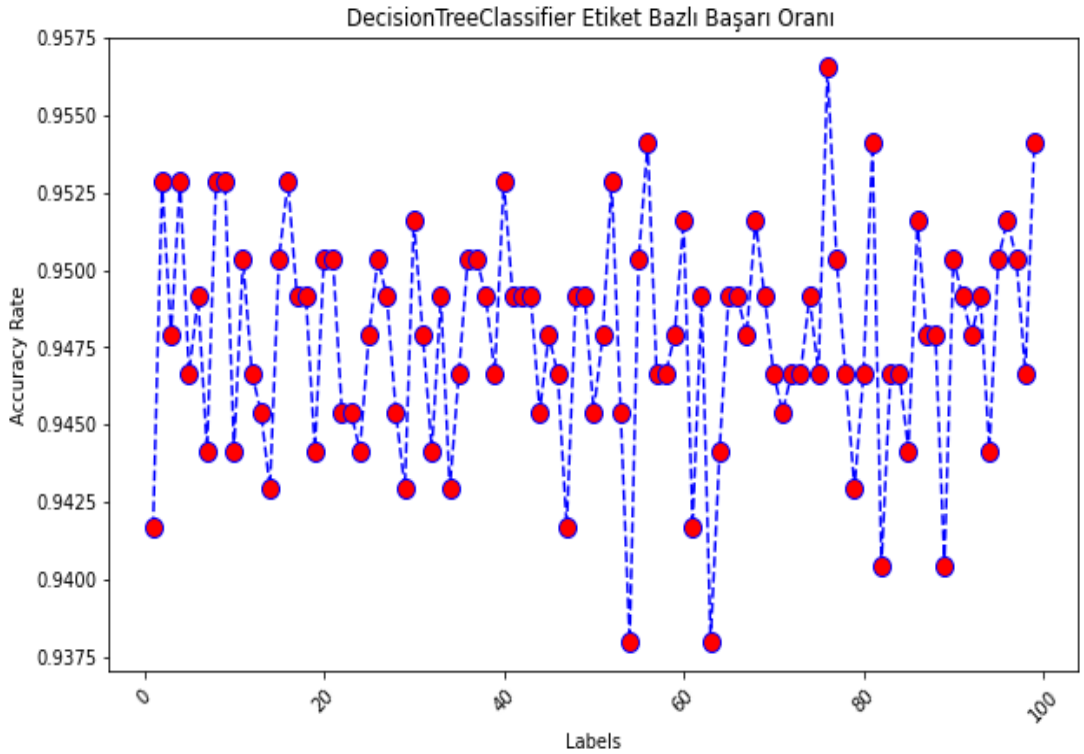
Çizelge 1 K-NN İçin Tüm Etiketler Hata Matrix’i

	LYING_DOWN	LOC_home	LOC_main_workplace	SITTING	OR_standing	FIX_walking	SLEEPING
LYING_DOWN	SCS 691 F115	SCS 0 # F171	SCS 0 F141	SCS 0 # F167	SCS 0 # F57	SCS 0 # F12	SCS 0 # F101
LOC_home	SCS 0 F115	SCS 635 # F171	SCS 0 F141	SCS 0 # F167	SCS 0 # F57	SCS 0 # F12	SCS 0 # F101
LOC_main_workplace	SCS 0 F115	SCS 0 # F171	SCS 665 # F141	SCS 0 # F167	SCS 0 # F57	SCS 0 # F12	SCS 0 # F101
SITTING	SCS 0 F115	SCS 0 # F171	SCS 0 # F141	SCS 639 # F167	SCS 0 # F57	SCS 0 # F12	SCS 0 # F101
OR_standing	SCS 0 F115	SCS 0 # F171	SCS 0 # F141	SCS 0 # F167	SCS 749 # F57	SCS 0 # F12	SCS 0 # F101
FIX_walking	SCS 0 F115	SCS 0 # F171	SCS 0 # F141	SCS 0 # F167	SCS 0 # F57	SCS 794 # F12	SCS 0 # F101
SLEEPING	SCS 0 F115	SCS 0 # F171	SCS 0 # F141	SCS 0 # F167	SCS 0 # F57	SCS 0 # F12	SCS 705 # F101

## 2. Karar Ağacı Analiz Sonuçları

Karar Ağacı, bir veri kümesini sınıflandırmak veya regresyon yapmak için kullanılan bir makine öğrenimi algoritmasıdır. Temelde ağaç yapısına sahiptir, bu ağaç her iç düğümde bir özellik testi yapar ve her yaprak düğümünde bir sınıf etiketi veya bir sayısal değer bulunur.

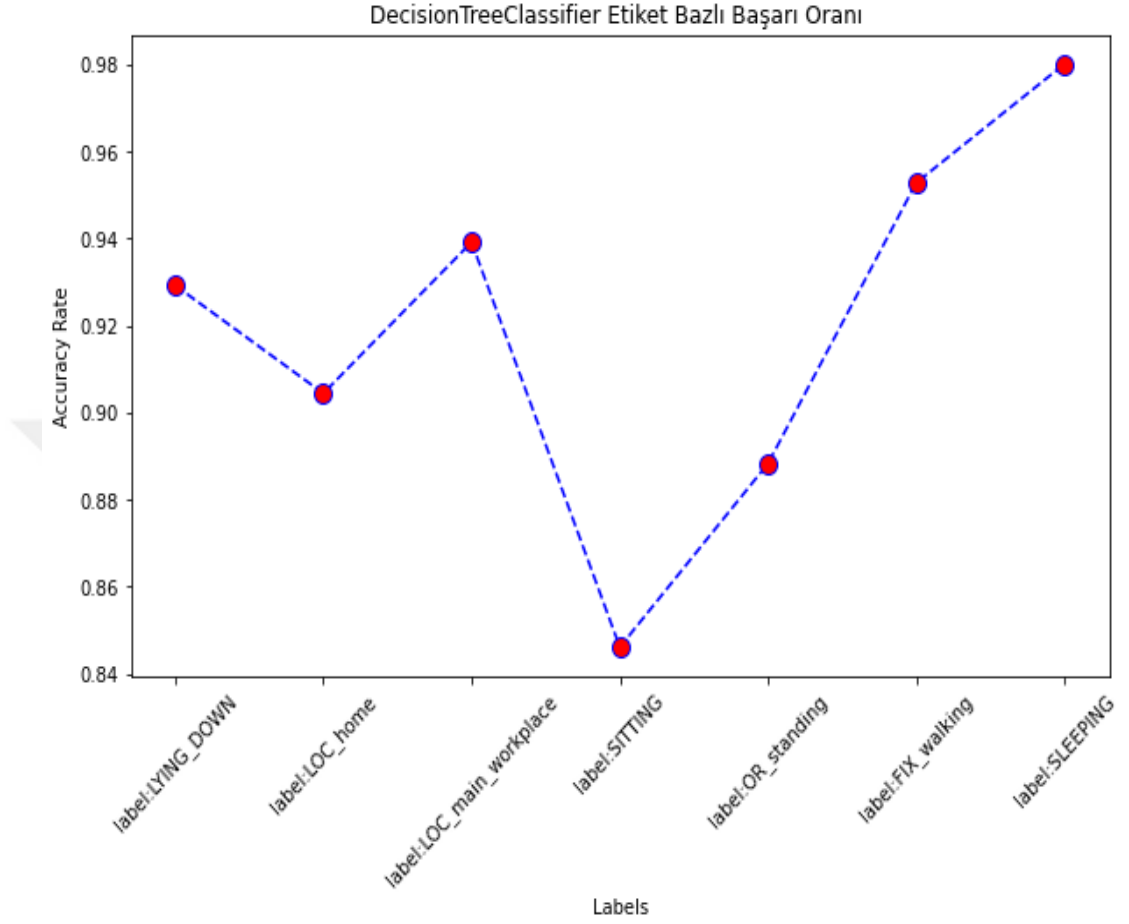
Karar ağaçları eğitim veri setine aşırı uyum sağlama eğilimindedir. Bu durumu kontrol etmek için ağacın derinliği sınırlandırılmalıdır. Bu amaçla Karar ağaçları, veri kümesini bölme sırasında ve özellik seçimi sırasında rastgele öğeleri kullanılmalıdır. Rastgeleliğin kontrolü amacıyla algoritmada `random_state` parametresinin dikkatli olarak seçilmesi gereklidir. En uygun `random_state` değerinin tespit edilmesi amacıyla 1-100 arasında değerlerin tamamı denenerek elde edilen başarı oranlarına bakılmıştır. Elde edilen sonuçların 2, 8, 9 ve 76 değerlerinden sağlandığı tespit edilmiştir. Başarı oranları ile ilgili sonuçlar Şekil 7’de verilmiştir.



Şekil 7 Karar Ağacı Algoritması `Random_state` Parametre Seçim Sonuçları

Algoritmanın düşük maliyet ile çalışması ve ortalama başarı oranının 8 değeri için yüksek olması nedeniyle `random_state` değeri 8 olarak seçilmiştir. Seçilen değer üzerinden tüm etiketler için yapılan değerlendirmede en yüksek başarı SLEEPING ve en düşük SITTING etiketlerinde elde edilmiş olup elde edilen sonuçlar sırası ile

%98.08 ve %84.61'dir. Elde edilen sonuçlara göre tüm etiketler için ortalama başarı oranı %92.55'tir. Şekil 8'de karar ağacı algoritmasının tüm etiketlere uygulanması sonucu elde edilen başarı oranları verilmiştir.



Şekil 8 Karar Ağacı Algoritması İçin Tüm Etiketler İçin Başarı Sonuçları

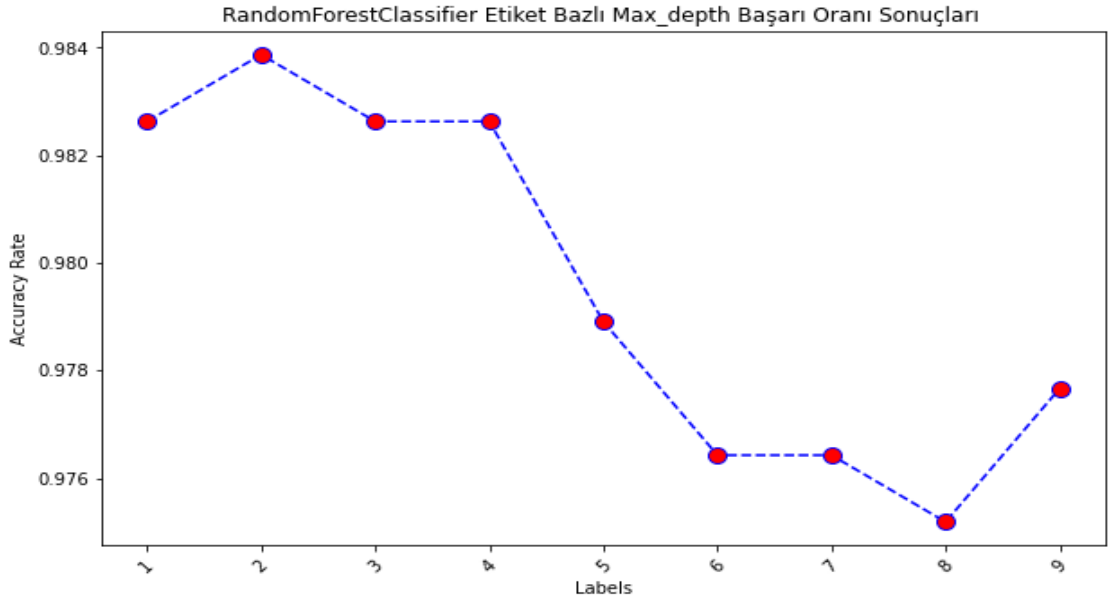
Çizelge 2, Karar Ağacı Algoritması ile gerçekleştirilen bir sınıflandırma çalışmasının sonuçlarını içermektedir. En başarılı sınıflandırma sonucu Sleeping (SCS 781)etiketinde elde edilmiştir. En düşük sınıflandırma başarısı SITTING (SCS 701) etiketinde elde edilmiştir.

Çizelge 2 Karar Ağacı Algoritması İçin Tüm Etiketler Hata Matrix'i

	LYING_DOW N	LOC_hom e	LOC_main_workpla ce	SITTIN G	OR_standin g	FIX_walkin g	SLEEPIN G
LYING_DOWN	SCS 745 F61	SCS 0 # F85	SCS 0 # F49	SCS 0 # F105	SCS 0 # F62	SCS 0 # F33	SCS 0 # F25
LOC_home	SCS 0 # F61	SCS 721 # F85	SCS 0 # F49	SCS 0 # F105	SCS 0 # F62	SCS 0 # F33	SCS 0 # F25
LOC_main_workpla ce	SCS 0 # F61	SCS 0 # F85	SCS 757 # F49	SCS 0 # F105	SCS 0 # F62	SCS 0 # F33	SCS 0 # F25
SITTING	SCS 0 # F61	SCS 0 # F85	SCS 0 # F49	SCS 701 # F105	SCS 0 # F62	SCS 0 # F33	SCS 0 # F25
OR_standing	SCS 0 # F61	SCS 0 # F85	SCS 0 # F49	SCS 0 # F105	SCS 744 # F62	SCS 0 # F33	SCS 0 # F25
FIX_walking	SCS 0 # F61	SCS 0 # F85	SCS 0 # F49	SCS 0 # F105	SCS 0 # F62	SCS 773 # F33	SCS 0 # F25
SLEEPING	SCS 0 # F61	SCS 0 # F85	SCS 0 # F49	SCS 0 # F105	SCS 0 # F62	SCS 0 # F33	SCS 781 # F25

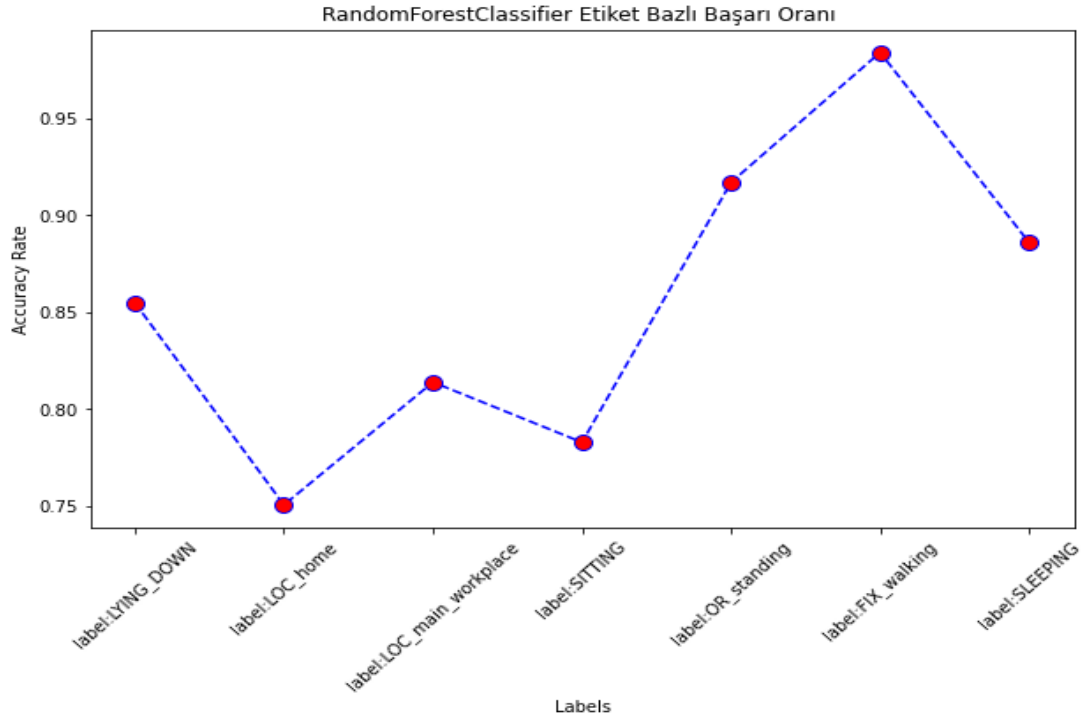
### 3. Rastgele Orman Sınıflandırma Sonuçları

Rastgele Orman Sınıflandırma (RF) algoritması, sınıflandırma problemleri için kullanılan bir uygulamasıdır. Her bir ağaç, bir örneklem seti üzerinden rastgele seçilmiş özelliklere dayanarak ayrı ayrı eğitilir. Bu özellik, her bir ağacın birbirinden farklı özelliklere odaklanmasını sağlar, bu da modelin daha çeşitli ve güçlü olmasına olanak tanır. RF algoritmasının verimli olarak çalışması için gerekli parametrelerden biri max\_depth'tir. Bu parametrenin alacağı değerler üretilen ağaçların derinliğini veyahut karmaşıklığı belirlemektedir. Düşük bir değerin seçilmesi, ağaç yapısının yüzeysel olarak kalmasını ve öğrenme performansının azalmasına neden olmaktadır. Yüksek bir değerin seçilmesi ağaç yapısını karmaşıklaştırır iken öğrenmeyi arttırmaktadır. Ancak yüksek değerin getirdiği sonuçlardan biri aşırı öğrenmedir. Bu değerin en uygun olarak seçilmesi amacıyla yapılan değerlendirmede en iyi sonucun 2 olarak seçilmesi durumunda gerçekleştiği tespit edilmiştir. En uygun parametre değerinin seçimine yönelik gerçekleştirilen çalışmanın sonuçları Şekil 9'da verilmiştir.



Şekil 9 Rastgele Orman Algoritması Max\_depth Parametre Seçim Sonuçları

RF algoritmasının max\_depth değerinin belirmesi sonucunda elde edilen sonuçlar Şekil 10'da verilmiştir elde edilen sonuçlara göre en yüksek başarı FIX\_walking ve en düşük SITTING etiketlerinde elde edilmiş olup elde edilen sonuçlar sırası ile %98.38 ve %78.28'dir.



Şekil 10 RF Algoritması Tüm Etiketler İçin Başarı Sonuçları

Çizelge 3, RF algoritması ile gerçekleştirilen sınıflandırmayı içermektedir. Çizelgedan anlaşılacağı üzere, en başarılı sınıflandırma sonucu SLEEPING etiketinde elde edilmiş ve doğru sınıflandırma sayısı (SCS) 791 olarak belirtilmiştir. Bu, RF algoritmasının SLEEPING etiketini diğer etiketlere göre en iyi şekilde sınıflandırdığını göstermektedir.

En düşük sınıflandırma başarısı ise SITTING etiketinde elde edilmiş ve SCS değeri 728 olarak verilmiştir. Bu, RF algoritmasının diğer etiketlere göre SITTING etiketini daha az doğru bir şekilde sınıflandırdığını göstermektedir.

Çizelge 3 RF Algoritması İçin Tüm Etiketler Hata Matrix'i

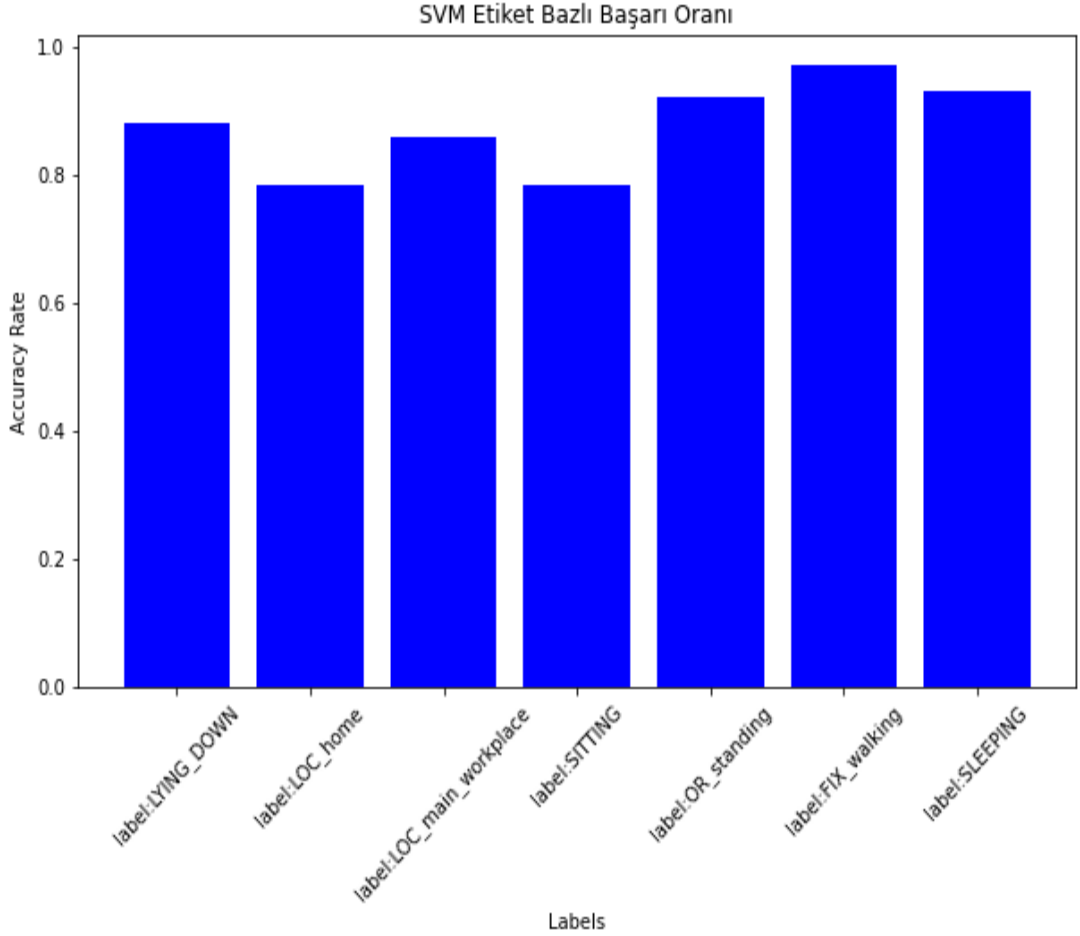
	LYING_DOWN	LOC_home	LOC_main_work place	SITTING	OR_standing	FIX_walking	SLEEPING
LYING_DOWN	SCS 775 # F31	SCS 0 # F38	SCS 0 # F35	SCS 0 # F78	SCS 0 # F45	SCS 0 # F17	SCS 0 # F15
LOC_home	SCS 0 # F31	SCS 768 # F38	SCS 0 # F35	SCS 0 # F78	SCS 0 # F45	SCS 0 # F17	SCS 0 # F15
LOC_main_work place	SCS 0 # F31	SCS 0 # F38	SCS 771 # F35	SCS 0 # F78	SCS 0 # F45	SCS 0 # F17	SCS 0 # F15
SITTING	SCS 0 # F31	SCS 0 # F38	SCS 0 # F35	SCS 728 # F78	SCS 0 # F45	SCS 0 # F17	SCS 0 # F15
OR_standing	SCS 0 # F31	SCS 0 # F38	SCS 0 # F35	SCS 0 # F78	SCS 761 # F45	SCS 0 # F17	SCS 0 # F15
FIX_walking	SCS 0 # F31	SCS 0 # F38	SCS 0 # F35	SCS 0 # F78	SCS 0 # F45	SCS 789 # F17	SCS 0 # F15
SLEEPING	SCS 0 # F31	SCS 0 # F38	SCS 0 # F35	SCS 0 # F78	SCS 0 # F45	SCS 0 # F17	SCS 791 # F15

#### 4. Destek Vektör Makineleri Analiz Sonuçları

Destek Vektör Makineleri (Support Vector Machines veya SVM), özellikle sınıflandırma ve regresyon problemleri için kullanılan bir makine öğrenimi algoritmasıdır. SVM, veri noktalarını bir uzayda sınıflandırmak veya regresyon analizi yapmak için kullanılır. SVM'nin temel amacı, iki sınıf arasındaki en iyi ayrımı bulmaktır.

SVM'ye yönelik yapılan uygulamada en iyi sonuçların elde edilmesine yönelik parametre olarak gamma ve kernel parametrelerinin varsayılan değerler dışında seçilmesi gerekliliği tespit edilmiştir. Bu amaçla seçili parametreler gamma ve kernel

için sırası ile 0,1 ve linear belirlenmiştir. Gamma parametresi çekirdek fonksiyonunun genişliğini kontrol etmektedir. Büyük bir gamma değeri, daha karmaşık bir model oluşturmaktadır ve eğitim veri setine daha fazla odaklanmaktadır. Çekirdek parametresi veri parametrelerinin oluşturduğu uzayda doğrusal ve doğrusal olmayan ayırımın verimli olarak gerçekleştirilmesi bağlamında önemlidir.



Şekil 11. SVM Algoritması Tüm Etiketler İçin Başarı Sonuçları

Tüm sınıfların SVM ile elde edilen başarı değerleri Şekil 11’de verilmiştir. Elde edilen sonuçlarda en yüksek başarı FIX\_walking ve en düşük başarı SITTING etiketlerinde edilmiş olup elde edilen değerler sırası ile %97 ve %78’dir. Tüm etiketlerin ortalama başarı oranı %87.55’dir.

Çizelge 4, SVM Algoritması kullanılarak gerçekleştirilen bir sınıflandırma çalışmasının sonuçlarını içermektedir. En başarılı sınıflandırma sonucu FIX\_walking etiketinde elde edilmiş ve doğru sınıflandırma sayısı (SCS) 782 olarak belirtilmiştir.

Bu, SVM algoritmasının FIX\_walking etiketini diğer etiketlere göre en iyi şekilde sınıflandırdığını gösterir. En düşük sınıflandırma başarısı ise SITTING etiketinde elde edilmiş ve SCS değeri 631 olarak verilmiştir. Bu, SVM algoritmasının SITTING etiketini diğer etiketlere göre daha az doğru bir şekilde sınıflandırdığını gösterir.

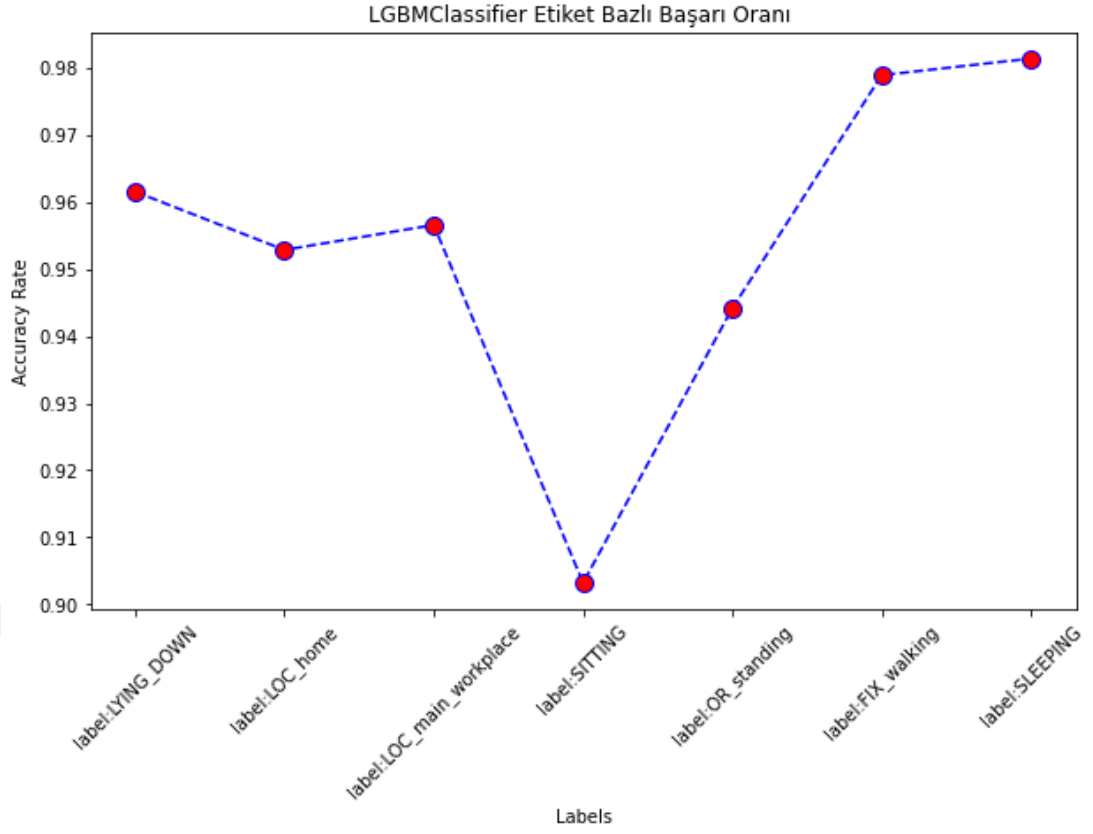
Çizelge 4 SVM Algoritması İçin Tüm Etiketler Hata Matrix’i

	LYING_DOWN	LOC_home	LOC_main_workplace	SITTING	OR_standing	FIX_walking	SLEEPING
LYING_DOWN	SCS 711 # F95	SCS 0 # F173	SCS 0 # F114	SCS 0 # F175	SCS 0 # F64	SCS 0 # F24	SCS 0 # F57
LOC_home	SCS 0 # F95	SCS 633 # F173	SCS 0 # F114	SCS 0 # F175	SCS 0 # F64	SCS 0 # F24	SCS 0 # F57
LOC_main_workplace	SCS 0 # F95	SCS 0 # F173	SCS 692 # F114	SCS 0 # F175	SCS 0 # F64	SCS 0 # F24	SCS 0 # F57
SITTING	SCS 0 # F95	SCS 0 # F173	SCS 0 # F114	SCS 631 # F175	SCS 0 # F64	SCS 0 # F24	SCS 0 # F57
OR_standing	SCS 0 # F95	SCS 0 # F173	SCS 0 # F114	SCS 0 # F175	SCS 742 # F64	SCS 0 # F24	SCS 0 # F57
FIX_walking	SCS 0 # F95	SCS 0 # F173	SCS 0 # F114	SCS 0 # F175	SCS 0 # F64	SCS 782 # F24	SCS 0 # F57
SLEEPING	SCS 0 # F95	SCS 0 # F173	SCS 0 # F114	SCS 0 # F175	SCS 0 # F64	SCS 0 # F24	SCS 749 # F57

## 5. LGBMClassifier Analiz Sonuçları

LGBMClassifier, LightGBM kütüphanesindeki bir sınıflandırıcıdır. LightGBM, hız ve performans optimizasyonu ile bilinen bir gradient boosting framework'üdür. Gradient boosting, zayıf öğrencileri (genellikle karar ağaçları) bir araya getirerek güçlü bir öğrenci oluşturan bir ensemble (ansambl) yöntemidir.

Bu sınıflandırma algoritması ile elde edilen sonuçlar değerlendirildiğinde elde edilen sonuçlarda en yüksek başarı SLEEPING ve en düşük başarı SITTING etiketlerinde edilmiş olup elde edilen değerler sırası ile %98.13 ve %90.32'dir. Tüm etiketlerin ortalama başarı oranı %95.40'dır. Tüm sınıfların LGBMClassifier ile elde edilen başarı değerleri Şekil 12'de verilmiştir.



Şekil 12 LGBMClassifier İçin Tüm Etiketlerin Başarı Sonuçları

Çizelge 5, LGBMClassifier (LightGBM Classifier) Algoritması kullanılarak gerçekleştirilen bir sınıflandırma çalışmasının sonuçlarını içermektedir. En başarılı sınıflandırma sonucu SLEEPING etiketinde elde edilmiş ve doğru sınıflandırma sayısı (SCS) 790 olarak belirtilmiştir. Bu, LGBMClassifier algoritmasının SLEEPING etiketini diğer etiketlere göre en iyi şekilde sınıflandırdığını göstermektedir. En düşük sınıflandırma başarısı ise SITTING etiketinde elde edilmiş ve SCS değeri 725 olarak verilmiştir. Bu, LGBMClassifier algoritmasının SITTING etiketini diğer etiketlere göre daha az doğru bir şekilde sınıflandırdığını ifade etmektedir.

	LYING_DOWN	LOC_home	LOC_main_workplace	SITTING	OR_standing	FIX_walking	SLEEPING
LYING_DOWN	SCS 773 # F33	SCS 0 # F35	SCS 0 # F36	SCS 0 # F81	SCS 0 # F45	SCS 0 # F18	SCS 0 # F16
LOC_home	SCS 0 # F33	SCS 771 # F35	SCS 0 # F36	SCS 0 # F81	SCS 0 # F45	SCS 0 # F18	SCS 0 # F16
LOC_main_workplace	SCS 0 # F33	SCS 0 # F35	SCS 770 # F36	SCS 0 # F81	SCS 0 # F45	SCS 0 # F18	SCS 0 # F16
SITTING	SCS 0 # F33	SCS 0 # F35	SCS 0 # F36	SCS 725 # F81	SCS 0 # F45	SCS 0 # F18	SCS 0 # F16
OR_standing	SCS 0 # F33	SCS 0 # F35	SCS 0 # F36	SCS 0 # F81	SCS 761 # F45	SCS 0 # F18	SCS 0 # F16
FIX_walking	SCS 0 # F33	SCS 0 # F35	SCS 0 # F36	SCS 0 # F81	SCS 0 # F45	SCS 788 # F18	SCS 0 # F16

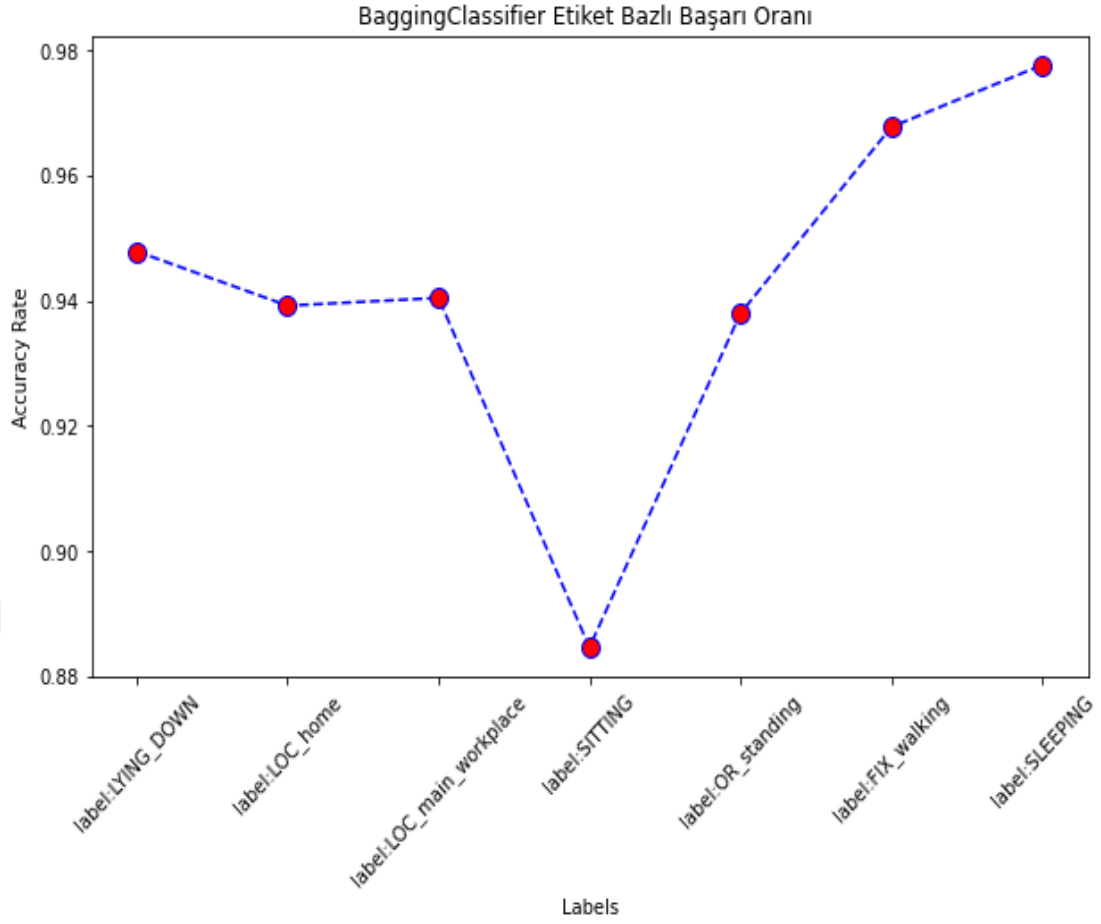
Çizelge 5 LGBMClassifier Algoritması İçin Tüm Etiketler Hata Matrix'i

SLEEPING	SCS 0 # F33	SCS 0 # F35	SCS 0 # F36	SCS 0 # F81	SCS 0 # F45	SCS 0 # F18	SCS 790 # F16
----------	-------------	-------------	-------------	-------------	-------------	-------------	---------------

## 6. Bootstrap Aggregating Sınıflandırıcı

Bootstrap Aggregating Sınıflandırıcı (BaggingClassifier), ansambil öğrenme (ensemble learning) yöntemlerinden biri olan bagging'in bir uygulamasıdır. Bagging, birbiriyle zayıf ilişkili birden çok modelin bir araya getirilerek daha güçlü bir model oluşturulması fikrine dayanır. BaggingClassifier, bu yöntemi sınıflandırma problemleri için kullanılmaktadır. Bu algoritma farklı alt-veri kümeleri üzerinde aynı sınıflandırma algoritmasını (örneğin, karar ağacı) uygular ve bu modelleri bir araya getirmektedir.

BaggingClassifier algoritmasının karar ağacı algoritması ile yapılan uygulamada tüm etiketler için gerçekleştirilen değerlendirmede en iyi başarı değeri SLEEPING ve en düşük başarı değeri SITTING etiketinde elde edilmiştir. Elde edilen değerlendirme sonuçları Şekil 13'te verilmiştir. Elde edilen başarı değerlerinin ortalama değeri %94.22'dir.



Şekil 13 BaggingClassifier İçin Tüm Etiketler İçin Başarı Sonuçları

Çizelge 6, BaggingClassifier Algoritması kullanılarak gerçekleştirilen bir sınıflandırma çalışmasının sonuçlarını içermektedir. En başarılı sınıflandırma sonucu FIX\_walking ve SLEEPING etiketinde elde edilmiş ve doğru sınıflandırma sayısı (SCS) 787 olarak elde edilmiştir. Bu, BaggingClassifier algoritmasının FIX\_walking ve SLEEPING etiketini diğer etiketlere göre en iyi şekilde sınıflandırdığını gösterir.

En düşük sınıflandırma başarısı ise SITTING etiketinde elde edilmiş ve SCS değeri 723 olarak verilmiştir. Bu, BaggingClassifier algoritmasının SITTING etiketini diğer etiketlere göre daha az doğru bir şekilde sınıflandırdığını gösterir.

Çizelge 6 BaggingClassifier Algoritması İçin Tüm Etiketler Hata Matrix'i

	LYING_DOWN	LOC_home	LOC_main_workplace	SITTING	OR_standing	FIX_walking	SLEEPING
LYING_DOWN	SCS 764 # F42	SCS 0 # F57	SCS 0 # F35	SCS 0 # F83	SCS 0 # F43	SCS 0 # F19	SCS 0 # F19
LOC_home	SCS 0 # F42	SCS 749 # F57	SCS 0 # F35	SCS 0 # F83	SCS 0 # F43	SCS 0 # F19	SCS 0 # F19
LOC_main_workplace	SCS 0 # F42	SCS 0 # F57	SCS 771 # F35	SCS 0 # F83	SCS 0 # F43	SCS 0 # F19	SCS 0 # F19
SITTING	SCS 0 # F42	SCS 0 # F57	SCS 0 # F35	SCS 723 # F83	SCS 0 # F43	SCS 0 # F19	SCS 0 # F19
OR_standing	SCS 0 # F42	SCS 0 # F57	SCS 0 # F35	SCS 0 # F83	SCS 763 # F43	SCS 0 # F19	SCS 0 # F19
FIX_walking	SCS 0 # F42	SCS 0 # F57	SCS 0 # F35	SCS 0 # F83	SCS 0 # F43	SCS 787 # F19	SCS 0 # F19
SLEEPING	SCS 0 # F42	SCS 0 # F57	SCS 0 # F35	SCS 0 # F83	SCS 0 # F43	SCS 0 # F19	SCS 787 # F19

## 7. Evrişimsel Sinir Ağları Analiz Sonuçları

Evrişimli Sinir Ağı (Convolutional Neural Network - CNN), özellikle görüntü ve video gibi yapısal verilerle çalışmak üzere tasarlanmış bir derin öğrenme modelidir. CNN'ler, girdi verisinde özellikleri çıkarmak ve hiyerarşik özellikler öğrenmek için konvolüsyon işlemlerini kullanmaktadır. Bir filtre (kernel) matrisi ile girdi veri üzerinde kaydırma işlemi gerçekleştirilir. Bu işlem, girdi üzerinde farklı özellikleri belirlemek için kullanılmaktadır.

Her katmanının ardından bir aktivasyon fonksiyonu uygulanır. Sıkça kullanılan aktivasyon fonksiyonları arasında ReLU (Rectified Linear Unit) bulunmaktadır.

Havuzlama işlemi, konvolüsyon sonrasında elde edilen özellik haritalarını ölçeklendirme amacı taşımaktadır. Bu işlem, özellik haritalarının boyutunu küçültülmesi ve öğrenilen özellikleri korunmasını sağlar. En yaygın kullanılan havuzlama yöntemleri Max pooling ve average pooling'dir.

Veriler için gerçekleştirilen model özeti Şekil 14'te verilmiştir. Model 3 katmandan oluşmaktadır. İlk katmanda 250, ikinci katmanda 128, üçüncü katmanda 64 nöron oluşturulmuştur. Katmanlarda kernel değeri olarak 5 seçilmiştir. Her katman sonrası pool size değeri 2 olacak şekilde MaxPooling uygulanmıştır. Ardından değerler düzleştirilmiş olup önce 32'li dense ardından 1'li dense katmanı uygulanmıştır.

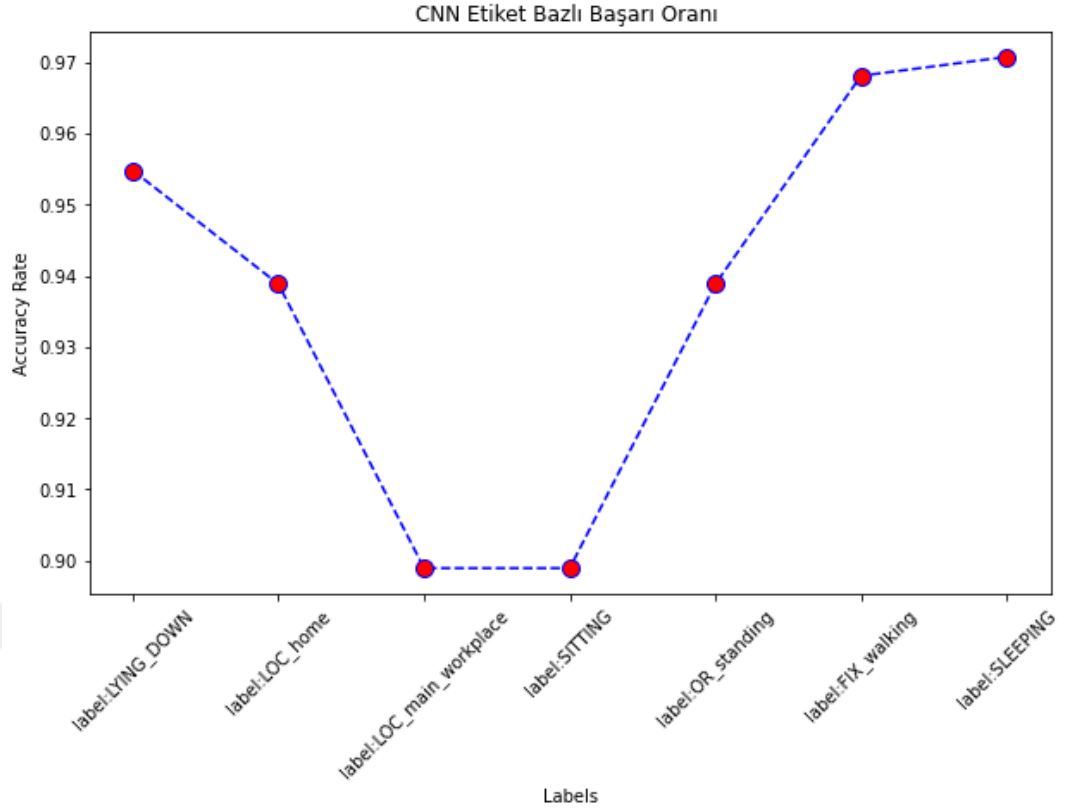
```
In [29]: model.summary()
Model: "sequential"
-----
```

Layer (type)	Output Shape	Param #
conv1d (Conv1D)	(None, 68, 250)	1500
max_pooling1d (MaxPooling1D)	(None, 34, 250)	0
conv1d_1 (Conv1D)	(None, 30, 128)	160128
max_pooling1d_1 (MaxPooling1D)	(None, 15, 128)	0
conv1d_2 (Conv1D)	(None, 11, 64)	41024
max_pooling1d_2 (MaxPooling1D)	(None, 5, 64)	0
flatten (Flatten)	(None, 320)	0
dense (Dense)	(None, 32)	10272
dense_1 (Dense)	(None, 1)	33

```
-----
Total params: 212957 (831.86 KB)
Trainable params: 212957 (831.86 KB)
Non-trainable params: 0 (0.00 Byte)
-----
```

Şekil 14 CNN Model Özeti

Model batch\_size 32 olacak şekilde 100 epoch üzerinden eğitilmiştir. Elde edilen sonuçlar değerlendirildiğinde en yüksek başarı değeri SLEEPING etiketinde %97.07 ile elde edildiği anlaşılmaktadır. Değerlendirmeye tabi tutulan etiketler arasında en düşük başarı oranı %89.89 ile SITTING etiketinde tespit edilmiştir. Tüm etiketlerin ortalama başarı değeri %93.84'tür. Tüm etiketlerin başarı oranları Şekil 15'te verilmiştir.



Şekil 15 CNN İçin Tüm Etiketlerin Başarı Sonuçları

Çizelge 7, CNN kullanılarak gerçekleştirilen bir sınıflandırma çalışmasının sonuçlarını barındırmaktadır. En başarılı sınıflandırma sonucu SLEEPING etiketinde elde edilmiş ve doğru sınıflandırma sayısı (SCS) 773 olarak belirtilmiştir. Bu, CNN algoritmasının SLEEPING etiketini diğer etiketlere göre en iyi şekilde sınıflandırdığını ortaya koymaktadır. En düşük sınıflandırma başarısı ise LOC\_home etiketinde elde edilmiş ve SCS değeri 697 olarak verilmiştir. Bu, CNN algoritmasının LOC\_home etiketini diğer etiketlere göre daha az doğru bir şekilde sınıflandırdığını gösterir.

Çizelge 7 CNN İçin Tüm Etiketlerin Hata Matrix'i

	LYING_DOW N	LOC_hom e	LOC_main_workpla ce	SITTIN G	OR_standin g	FIX_walkin g	SLEEPIN G
LYING_DOWN	SCS 751 # F55	SCS 0 # F109	SCS 0 # F87	SCS 0 # F103	SCS 0 # F79	SCS 0 # F36	SCS 0 # F33
LOC_home	SCS 0 # F55	SCS 697 # F109	SCS 0 # F87	SCS 0 # F103	SCS 0 # F79	SCS 0 # F36	SCS 0 # F33
LOC_main_workpla ce	SCS 0 # F55	SCS 0 # F109	SCS 719 # F87	SCS 0 # F103	SCS 0 # F79	SCS 0 # F36	SCS 0 # F33
SITTING	SCS 0 # F55	SCS 0 # F109	SCS 0 # F87	SCS 703 # F103	SCS 0 # F79	SCS 0 # F36	SCS 0 # F33
OR_standing	SCS 0 # F55	SCS 0 # F109	SCS 0 # F87	SCS 0 # F103	SCS 727 # F79	SCS 0 # F36	SCS 0 # F33
FIX_walking	SCS 0 # F55	SCS 0 # F109	SCS 0 # F87	SCS 0 # F103	SCS 0 # F79	SCS 770 # F36	SCS 0 # F33
SLEEPING	SCS 0 # F55	SCS 0 # F109	SCS 0 # F87	SCS 0 # F103	SCS 0 # F79	SCS 0 # F36	SCS 773 # F33

## 8. Tekrarlayan Sinir Ağları Analiz Sonuçları

Tekrarlayan Sinir Ağları (RNN), sıralı veri ve zaman serisi gibi yapısal verilerle çalışmak üzere tasarlanmış bir tür derin öğrenme modelidir. RNN'ler, geçmiş zamandaki bilgiyi bellekte saklayabilme yeteneği ile sıralı veri setlerindeki bağımlılıkları daha etkili bir şekilde öğrenmeye çalışmaktadır. Bu model, önceki girdilere dayanarak sonraki girdiyi tahmin edebilme yeteneği ile öne çıkmaktadır.

RNN'ler, geçmiş zamandaki girdilerin etkisini koruyabilmek için bir tür hafıza mekanizması kullanmaktadır. Bu, modelin önceki adımlarda öğrendiği bilgileri gelecekteki adımlarda kullanmasına olanak tanımaktadır.

RNN'ler genellikle geriye yayılım (backpropagation) algoritması ile eğitilmektedir. Ancak, bu süreç bazen "uzun vadeli bağımlılık sorunu" nedeniyle zorlayıcı olabilmektedir.

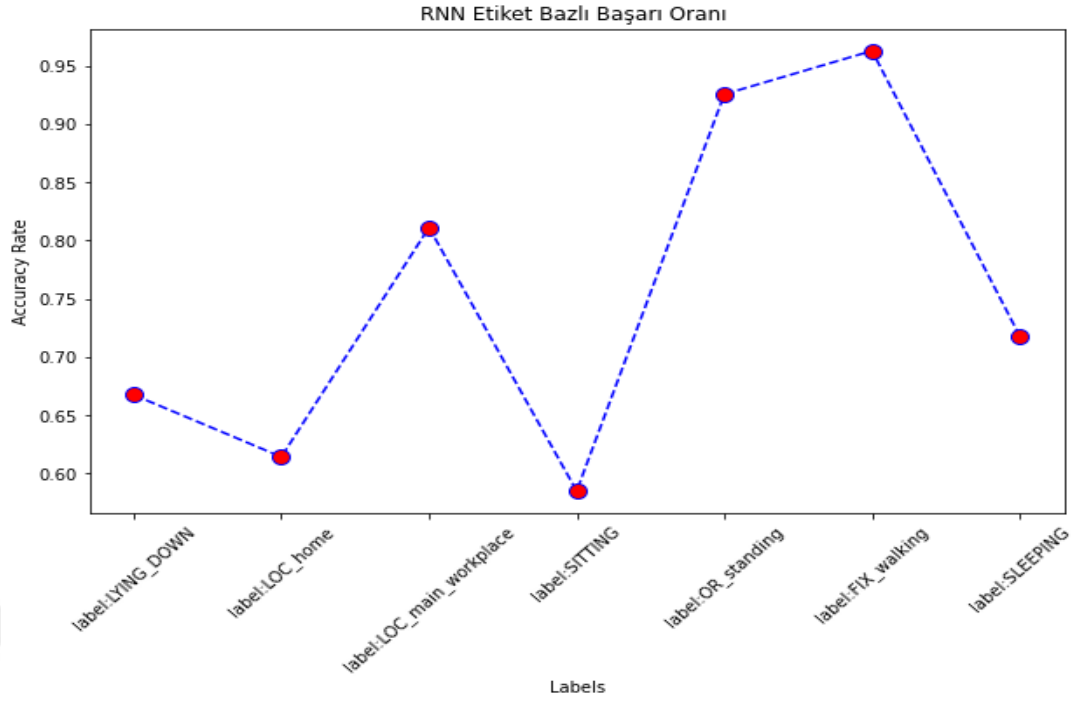
Bu zorluk, gelişmiş RNN türleri ve türetilmiş modellerle (LSTM, GRU gibi) aşılmaya çalışılmaktadır.

Gerçekleştirilen uygulamada kurulan model 3 katmandan oluşmaktadır. İlk katmanda LSTM ile 128, ikinci katmanda LSTM ile 64 ve üçüncü katmanda LSTM ile 32 nöron oluşturulmuştur. Sadece üçüncü katmanda nöronların %20'i dropout edilmiştir. Kurulan modelin özet bilgisi Şekil 16'da verilmiştir.

```
Model: "sequential_16"
-----
Layer (type)                Output Shape                Param #
-----
lstm (LSTM)                  (None, 72, 128)            66560
lstm_1 (LSTM)                (None, 72, 64)             49408
lstm_2 (LSTM)                (None, 32)                  12416
dropout (Dropout)           (None, 32)                   0
dense_32 (Dense)            (None, 1)                    33
-----
Total params: 128417 (501.63 KB)
Trainable params: 128417 (501.63 KB)
Non-trainable params: 0 (0.00 Byte)
```

Şekil 16 RNN Model Özeti

Kurulan model, batch\_size 32 olacak şekilde 100 epoch üzerinden eğitilmiştir. Elde edilen sonuçlar değerlendirildiğinde en yüksek başarı değeri *FIX\_walking* etiketinde %96.27 ile elde edildiği anlaşılmaktadır. Değerlendirmeye tabi tutulan etiketler arasında en düşük başarı oranı %58.51 ile *SITTING* etiketinde tespit edilmiştir. Tüm etiketlerin ortalama başarı değeri %93.84'tür. Tüm etiketlerin başarı oranları Şekil 17'de verilmiştir.



Şekil 17 RNN İçin Tüm Etiketler Başarı Sonuçları


Çizelge 7, CNN kullanılarak gerçekleştirilen bir sınıflandırma çalışmasının sonuçlarını barındırmaktadır. En başarılı sınıflandırma sonucu FIX\_walking etiketinde elde edilmiş ve doğru sınıflandırma sayısı (SCS) 773 olarak belirtilmiştir. Bu, CNN algoritmasının FIX\_walking etiketini diğer etiketlere göre en iyi şekilde sınıflandırdığını ortaya koymaktadır. En düşük sınıflandırma başarısı ise SITTING etiketinde elde edilmiş ve SCS değeri 572 olarak verilmiştir. Bu, CNN algoritmasının SITTING etiketini diğer etiketlere göre daha az doğru bir şekilde sınıflandırdığını gösterir.

Çizelge 8 CNN İçin Tüm Etiketlerin Hata Matrix'i

	LYING_DOW N	LOC_hom e	LOC_main_workpla ce	SITTIN G	OR_standin g	FIX_walkin g	SLEEPIN G
LYING_DOWN	SCS 703 # F103	SCS 0 # F109	SCS 0 # F87	SCS 0 # F234	SCS 0 # F79	SCS 0 # F33	SCS 0 # F36
LOC_home	SCS 0 # F103	SCS 697 # F109	SCS 0 # F87	SCS 0 # F234	SCS 0 # F79	SCS 0 # F33	SCS 0 # F36
LOC_main_workpla ce	SCS 0 # F103	SCS 0 # F109	SCS 719 # F87	SCS 0 # F234	SCS 0 # F79	SCS 0 # F33	SCS 0 # F36
SITTING	SCS 0 # F103	SCS 0 # F109	SCS 0 # F87	SCS 572 # F234	SCS 0 # F79	SCS 0 # F33	SCS 0 # F36
OR_standing	SCS 0 # F103	SCS 0 # F109	SCS 0 # F87	SCS 0 # F234	SCS 727 # F79	SCS 0 # F33	SCS 0 # F36
FIX_walking	SCS 0 # F103	SCS 0 # F109	SCS 0 # F87	SCS 0 # F234	SCS 0 # F79	SCS 773 # F33	SCS 0 # F36
SLEEPING	SCS 0 # F103	SCS 0 # F109	SCS 0 # F87	SCS 0 # F234	SCS 0 # F79	SCS 0 # F33	SCS 770 # F36

## 9. Topluluk Öğrenmesi (Ensemble Majority)

Çalışma boyunca birden fazla makine öğrenmesi algoritması ve yapay sinir ağları uygulaması ile veri seti analizi gerçekleştirilmiştir. Ancak genel olarak elde edilen sonuçların tek başına kullanılması durumunda optimal değerlendirmenin eksik kaldığı tespit edilmiştir. Bu amaçla topluluk öğrenmesi yöntemi ile çoğunluk açısından tespit edilen etiketin nihai etiket olarak belirlenmesi yoluna gidilmiştir. Bu amaçla her bir analizden elde edilen sonuç True ve False olarak değerlendirmeye alınmış ve veri setinde bulunan etiket değerleri ile karşılaştırması gerçekleştirilmiştir. Elde edilen sonuçlar Şekil 18'de çizgi grafik üzerinde sunulmuştur.



Şekil 18 Topluluk Öğrenmesi İçin Tüm Etiketlerin Başarı Sonuçları



## V. SONUÇ

Bu çalışma, K-NN, Karar Ağacı, Rastgele Orman Sınıflandırma, SVM, LGBMClassifier, BaggingClassifier, Evrişimsel Sinir Ağları (CNN), ve Tekrarlayan Sinir Ağları (RNN) algoritmalarının kullanılmasıyla yapılmıştır. Her bir algoritmanın performansını değerlendirmek amacıyla farklı parametrelerle denemeler yapılmıştır.

K-NN tekniğinde, komşu sayısının doğru seçilmesinin başarı üzerinde kritik bir etkisi olduğu tespit edilmiştir. Yapılan değerlendirmeler sonucunda, 17 komşu sayısının en uygun seçim olduğu belirlenmiştir. Bu durumda, en düşük hata oranı elde edilmiştir.

Karar Ağacı analizinde, random\_state parametresinin seçimi üzerine yapılan çalışmalar sonucunda en uygun değer 8 olduğu belirlenmiştir. Seçilen parametre değeri ile tüm etiketler üzerinde yapılan değerlendirmede en yüksek başarı FIX\_walking etiketinde elde edilmiştir.

Rastgele Orman Sınıflandırma sonuçlarına göre, max\_depth parametresinin en iyi sonucu 2 değeriyle verdiği belirlenmiştir. Bu durumda, en yüksek başarı FIX\_walking etiketinde elde edilmiştir.

SVM analizinde, gamma ve kernel parametrelerinin varsayılan değerler dışında seçilmesinin başarı üzerinde olumlu bir etki yaptığı tespit edilmiştir. Seçilen parametre değerleri ile tüm etiketler üzerinde yapılan değerlendirmede en yüksek başarı FIX\_walking etiketinde elde edilmiştir.

LGBMClassifier sonuçlarına göre, en yüksek başarı SLEEPING etiketinde elde edilmiştir. Bu algoritma ile tüm etiketler üzerinde yapılan değerlendirmede ortalama başarı oranı %95.40 olarak belirlenmiştir.

BaggingClassifier sonuçlarına göre, en iyi başarı SLEEPING etiketinde elde edilmiştir. Bu algoritma ile tüm etiketler üzerinde yapılan değerlendirmede ortalama başarı oranı %94.22 olarak belirlenmiştir.

Evrişimsel Sinir Ağları (CNN) sonuçlarına göre, en yüksek başarı SLEEPING etiketinde elde edilmiştir. Bu model ile tüm etiketler üzerinde yapılan değerlendirmede ortalama başarı oranı %93.84 olarak belirlenmiştir.

Tekrarlayan Sinir Ağları (RNN) analizine göre, en yüksek başarı FIX\_walking etiketinde elde edilmiştir. Ancak, SITTING etiketinde daha düşük bir başarı oranı tespit edilmiştir. Bu model ile tüm etiketler üzerinde yapılan değerlendirmede ortalama başarı oranı %93.84 olarak belirlenmiştir.

Çalışmada, makine öğrenmesi ve yapay sinir ağları uygulaması gerçekleştirilmiş elde edilen sonuçlar topluluk öğrenmesi yöntemi ile yeniden değerlendirmeye alınmıştır. Topluluk öğrenmesinde çoğunluk oylaması yöntemi ile etiketlerin sınıflandırması gerçekleştirilmiştir. Elde edilen sonuçlara göre en yüksek doğruluk SLEEPING etiketinde elde edilmiş olup başarı oranı %98,13'tür. Diğer bir taraftan elde edilen düşük başarı oranı SITTING etiketinde gerçekleşmiştir. SITTING etiketinde elde edilen başarı oranı %90,32'dir. Gerçekleştirilen topluluk öğrenmesi ile daha yüksek başarı elde edilmiş olup etiketler arası başarı dalgalanması azaltılmıştır.

Çalışmanın genelinde, her bir algoritmanın avantajları ve dezavantajları detaylı bir şekilde incelenmiştir. Elde edilen başarı oranları, model performansı ve parametre seçimleri üzerinden yapılan değerlendirmeler, bu algoritmaların uygunluğunu ve etkinliğini ortaya koymaktadır. Elde edilen sonuçlar, belirli etiketlerin tanımlanmasında en iyi performansı sağlayan modellerin belirlenmesine olanak tanımıştır. Bu çalışma, benzer etiketleme problemlerine yönelik gelecekteki araştırmalara ışık tutabilir ve karşılaşılan zorluklara çözüm sunabilir.

Sonuç olarak, farklı makine öğrenimi algoritmalarının kullanılmasıyla elde edilen sonuçlar incelendiğinde, her bir algoritmanın belirli etiketlerde daha yüksek başarı elde ettiği görülmüştür. Bu nedenle, belirli bir uygulama bağlamında en uygun algoritmanın seçilmesi, hedeflenen başarı oranına ulaşmak için önemli bir karar sürecidir.

## VI. KAYNAKLAR

### KİTAPLAR

ALPAYDIN, E. (2010). **Introduction To Machine Learning Second Edition**, The MIT Press, Cambridge, 4. Baskı.

MARVİN MİNSKY, S.A., (1988). **Perceptrons, Reissue Of The 1988**, Expanded Edition with a New Foreword By Léon Bottou: an introduction to computational geometry. MIT press.

NEGNEVITSKY, M., (2005). **Artificial Intelligence: A Guide To Intelligent Systems**. 2nd Ed., London: Pearson Education Limited.

RAMASUBRAMANIAN, K. ve SINGH, A. (2017). **Machine Learning Using R**, London: Springer.

DUNHAM, M.H. (2003). **Data Mining: Introductory and Advanced Topics**. Singapore: Pearson Education Inc.

### MAKALELER

AFZALİ ARANI, M. S., COSTA, D. E., & SHİHAB, E. (2021). "Human activity recognition: A comparative study to assess the contribution level of accelerometer, ecg, and ppg signals". **Sensors**, 21(21). doi: 10.3390/s21216997.

ALAWNEH, L., ALSARHAN, T., AL-ZİNATİ, M., AL-AYYOUB, M., JARARWEH, Y., & LU, H. (2021). "Enhancing human activity recognition using Deep Learning and time series augmented data". **Journal of Ambient Intelligence and Humanized Computing**, 12(12), 10565–10580. <https://doi.org/10.1007/s12652-020-02865-4>

ALHERSH, T., STUCKENSCHMİDT, H., REHMAN, A. U., & BELHAOUARİ, S. B. (2021). "Learning human activity from visual data using Deep Learning".

**IEEE Access**, 9, 106245–106253.  
<https://doi.org/10.1109/access.2021.3099567>

ALTUNCU, M.A., KAPLAN, K., KUNCAN, M., (2023). “Diagnosis of skin cancer confirmation methods using transfer learning”. **Social Science Research Network**, 4394434

AL-WESABİ, F. N., ALBRAİKAN, A. A., HİLAL, A. M., AL-SHARGABİ, A. A., ALHAZBİ, S., AL DUHAYYİM, M., RİZWANULLAH, M., & HAMZA, M. A. (2021). “Design of Optimal Deep Learning based human activity recognition on sensor enabled internet of things environment”. **IEEE Access**, 9, 143988–143996. <https://doi.org/10.1109/access.2021.3112973>

ANGUİTA, D., GHİO, A., ONETO, L., PARRA, X., & REYES-ORTİZ, J. L. (2013). “A public domain dataset for human activity recognition using smartphones”. **Esann** (Vol. 3, p. 3).

AYDIN, S. VE ÖZKUL, A. E. (2015). “Veri Madenciliği Ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama”, **Eğitim ve Öğretim Araştırmaları Dergisi**, cilt 4, sayı 3, ss.36-44.

BHAT, O., & KHAN, D. A. (2021).”Evaluation of deep learning model for human activity recognition”. **Evolving Systems**, 13(1), 159–168. <https://doi.org/10.1007/s12530-021-09373-6>

BİJALWAN, V., SEMWAL, V. B., & GUPTA, V. (2021). "Wearable sensor-based pattern mining for human activity recognition: Deep Learning Approach." **Industrial Robot: the International Journal of Robotics Research and Application**, 49(1), 21–33. <https://doi.org/10.1108/ir-09-2020-0187>

BOZKURT, F. (2021). "A comparative study on classifying human activities using classical machine and deep learning methods." **Arabian Journal for Science and Engineering**, 47(2), 1507–1521. <https://doi.org/10.1007/s13369-021-06008-5>

BUFFELLİ, D., & VANDİN, F. (2021). "Attention-based deep learning framework for human activity recognition with user adaptation." **IEEE Sensors Journal**, 21(12), 13474–13483. <https://doi.org/10.1109/jsen.2021.3067690>

- CHEN, L., LIU, X., PENG, L., & WU, M. (2020). "Deep Learning based multimodal complex human activity recognition using wearable devices." **Applied Intelligence**, 51(6), 4029–4042. <https://doi.org/10.1007/s10489-020-02005-7>
- DİLKİ, G., & DENİZ BAŞAR, Ö. (2020). "İşletmelerin İflas Tahmininde K- En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması." **İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi**, cilt 19, sayı 38, ss.224-233.
- ECER, F. (2013c). "Comparing the bank failure prediction performance of neural networks and support vector machines: The Turkish case." **Economic research-Ekonomska Istraživanja**, cilt 26, sayı 3, ss.81-98.
- ELSTS, A., & MCCONVILLE, R. (2021). "Are microcontrollers ready for deep learning-based human activity recognition?" **Electronics**, 10(21), 2640. <https://doi.org/10.3390/electronics10212640>
- FERRARİ, A., MÍCUCCI, D., MOBİLİO, M., & NAPOLETANO, P. (2022). "Deep learning and model personalization in sensor-based human activity recognition." **Journal of Reliable Intelligent Environments**, 2022:1-13. <https://doi.org/10.1007/s40860-021-00167-w>
- GHATE, V., & C, S. H. (2021). "Hybrid deep learning approaches for smartphone sensor-based human activity recognition." **Multimedia Tools and Applications**, 80(28-29), 35585–35604. <https://doi.org/10.1007/s11042-020-10478-4>
- HAİDER, B., (2008). "Contributions of yale neuroscience to donald o. hebb's organization of behavior." **The Yale Journal of Biology and Medicine**, 81(1), 11.
- HASSAN, M. M., ULLAH, S., HOSSAİN, M. S., & ALELAIWİ, A. (2020). "An end-to-end deep learning model for human activity recognition from highly sparse body sensor data in internet of medical things environment." **The Journal of Supercomputing**, 77(3), 2237–2250. <https://doi.org/10.1007/s11227-020-03361-4>
- HEGDE, N., BRİES, M., SWİBAS, T., MELANSON, E., & SAZONOV, E. (2018). "Automatic Recognition of Activities of Daily Living Utilizing Insole-Based

- and Wrist-Worn Wearable Sensors." **IEEE Journal of Biomedical and Health Informatics**, 22(4). doi: 10.1109/JBHI.2017.2734803.
- HOAI THU, N. T., & HAN, D. S. (2021). "Hihar: A hierarchical hybrid deep learning architecture for wearable sensor-based human activity recognition." **IEEE Access**, 9, 145271–145281. <https://doi.org/10.1109/access.2021.3122298>
- HOCHREITER, S., & SCHMIDHUBER, J. (1997). "Long short-term memory." **Neural Computation**, 9(8), 1735-1780.
- HOPFIELD, J.J., (1982). "Neural networks and physical systems with emergent collective computational abilities." **Proceedings of the National Academy of Sciences**, 79(8), 2554-2558.
- HU, L.Y., HUANG, M.W., KE, S.W., & TSAI, C.F. (2016). "The Distance Function Effect on k-Nearest Neighbor Classification for Medical Datasets." **Springer Plus**, cilt 5, sayı 1, ss.1-9.
- HWANG, Y. M., PARK, S., LEE, H. O., KO, S.-K., & LEE, B.-T. (2021). "Deep learning for human activity recognition based on causality feature extraction." **IEEE Access**, 9, 112257–112275. <https://doi.org/10.1109/access.2021.3103211>
- IRFAN, S., ANJUM, N., MASOOD, N., KHATTAK, A. S., & RAMZAN, N. (2021). "A novel hybrid deep learning model for human activity recognition based on transitional activities." **Sensors**, 21(24), 8227. <https://doi.org/10.3390/s21248227>
- KARTAL, C. (2020). "Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini." **İnsan ve Toplum Bilimleri Araştırmaları Dergisi**, cilt 9, sayı 2, ss.1394-1418.
- KAYA, Y., & KUNCAN, F. (2022). "A hybrid model for classification of medical data set based on factor analysis and extreme learning machine: FA + ELM." **Biomedical Signal Processing and Control**, 78, 104023.
- KAYA, Y., KUNCAN, F., & TEKİN, R. (2022). "A new approach for congestive heart failure and arrhythmia classification using angle transformation with

- LSTM." **Arabian Journal for Science and Engineering**, 47(8), 10497-10513.
- KHAN, A. R., SABA, T., KHAN, M. Z., FATI, S. M., & KHAN, M. U. (2022). "Classification of human's activities from gesture recognition in live videos using Deep Learning." **Concurrency and Computation: Practice and Experience**, 34(10). <https://doi.org/10.1002/cpe.6825>
- KHAN, D. Q., & PERRIZO, W. (2002). "K-nearest Neighbor Classification on Spatial Data Streams Using P-trees." **Advances in Knowledge Discovery and Data Mining**, sayı 2336, ss.517-528.
- KIZILKAYA, Y.M., & OĞUZLAR, A. (2018). "Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili İle Kıyaslanması." **Karadeniz Uluslararası Bilimsel Dergi**, sayı 37, ss.90-98.
- KÖSE, İ., ÖZTÜRK, S., & KUNCAN, M. (2019). "Pantography application with real-time PLC based on image processing in gantry robot system." **European Journal of Technic**, 9(2), 219-229.
- KRESSE, W., & DANKO, D. M. (2012). *Springer handbook of geographic information*. Springer Science & Business Media, Berlin.
- KRIZHEVSKY, A., SUTSKEVER, I., & HINTON, G.E., (2012). "ImageNet classification with deep convolutional neural networks." **Advances in Neural Information Processing Systems, Vol.25**.
- KUNCAN, F., KAYA, Y., YİNER, Z., & KAYA, M. (2022). "A new approach for physical human activity recognition from sensor signals based on motif patterns and long-short term memory." **Biomedical Signal Processing and Control**, 78, 103963.
- KÜÇÜKSİLLE, E. U., & ATEŞ, N. (2016). "Destek Vektör Makineleri ile Yaramaz Elektronik Postaların Filtrelenmesi." **Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi**, cilt 6, sayı 1, ss.1-7.
- LAVANYA, D., & RANI, K. U. (2011). "Performance Evaluation of Decision Tree Classifiers on Medical Datasets." **International Journal of Computer Applications**, cilt 26, sayı 4, ss.975-979.

- LECUN, Y., BENGIO, Y., & HINTON, G. (2015). "Deep Learning." **Nature**, sayı **521**, ss.436–444.
- LECUN, Y., BOTTOU, L., BENGIO, Y., & HAFFNER, P., (1998). "Gradient-based learning applied to document recognition." **Proceedings of the IEEE**, **86**(11), 2278-2324.
- LOH, W. Y. (2011). "Classification and Regression Trees." **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, cilt **1**, sayı **1**, ss.14- 23.
- MADOKORO, H., NIX, S., WOO, H., & SATO, K. (2021). "A mini-survey and feasibility study of deep-learning-based human activity recognition from slight feature signals obtained using privacy-aware environmental sensors." **Applied Sciences**, **11**(24), 11807.
- MAÎTRE, J., BOUCHARD, K., & GABOURY, S. (2021). "Alternative deep learning architectures for feature-level fusion in human activity recognition." **Mobile Networks and Applications**, **26**(5), 2076–2086.
- MANJARRES, J., LAN, G., GORLATOVA, M., HASSAN, M., & PARDO, M. (2022). "Deep learning for detecting human activities from piezoelectric-based kinetic energy signals." **IEEE Internet of Things Journal**, **9**(10), 7545–7558.
- MEKRUKSAVANICH, S., & JİTPATTANAKUL, A. (2021). "Deep convolutional neural network with rnns for complex activity recognition using wrist-worn wearable sensor data." **Electronics (Switzerland)**, vol. **10**, no. 14, doi: 10.3390/electronics10141685.
- MCCULLOCH, W.S., & PITTS, W., (1990). "A logical calculus of the ideas immanent in nervous activity, 1943." **Bulletin of mathematical biology**, **52**(1-2), 99-115.
- MEHRANG, S., PIETİLÄ, J., & KORHONEN, I. (2018). "An activity recognition framework deploying the random forest classifier and a single optical heart rate monitoring and triaxial accelerometer wristband." **Sensors (Switzerland)**, **18**(2). doi: 10.3390/s18020613.

- METLEK, S., & KAYAALP, K. (2020). "Derin öğrenme ve destek vektör makineleri ile görüntüden cinsiyet tahmini." **Düzce Üniversitesi Bilim ve Teknoloji Dergisi**, **8**(3), 2208-2228.
- MIKOLOV, T., KARAFIAT, M., BURGET, L., CERNOCK, J., & KHUDANPUR, S. (2010). "Recurrent neural network based language model." *Interspeech 2010*, ss.1045-1048.
- MİHOUB, A. (2021). "A deep learning-based framework for human activity recognition in Smart Homes." **Mobile Information Systems**, **2021**, 1–11, doi: 10.1155/2021/6961343.
- NGUYEN, M., FAN, L., & SHAHABİ, C. (2016). "Activity Recognition Using Wrist-Worn Sensors for Human Performance Evaluation." doi: 10.1109/ICDMW.2015.199.
- NUNAVATH, V., JOHANSEN, S., JOHANNESSEN, T. S., JİAO, L., HANSEN, B. H., BERNTSEN, S., & GOODWIN, M. (2021). "Deep learning for classifying physical activities from accelerometer data." **Sensors**, **21**(16), 5564.
- RONALD, M., POULOSE, A., & HAN, D. S. (2021). "ISPLInception: An inception-resnet deep learning architecture for human activity recognition." **IEEE Access**, **9**, 68985–69001, doi: 10.1109/access.2021.3078184.
- ROSTAMI, S., BAYAT, M., & JAVID, D., & ESMAEILPUOR, M. (2015). "Investigating The Effectiveness Of Machine Learning Algorithm On The Forecasting Of Tehran Stock Exchange Index." **Journal of Current Research in Science**, **cilt 3**, sayı 2, ss.162-169.
- SAMUEL, A.L., (1953.) "Computing bit by bit or digital computers made easy." **Proceedings of the IRE**, **41**(10), 1223-1230.
- SCHOLL, P. M., & VAN LAERHOVEN, K. (2012, July). "A feasibility study of wrist-worn accelerometer based detection of smoking habits." In 2012 Sixth International Conference on Innovative Mobile and Internet Services in Ubiquitous Computing (pp. 886-891). **IEEE**.
- SEYMOUR, S. (1997). "The Brain: Our Nervous System." New York: William Morrow.

- SHALABY, E., ELSHENNAWY, N., & SARHAN, A. (2022). "Utilizing deep learning models in CSI-based human activity recognition." **Neural Computing and Applications**, 34(8), 5993–6010. <https://doi.org/10.1007/s00521-021-06787-w>
- SHIEBER, S.M., (1994). "Lessons from a restricted Turing test." **Communications of the ACM**, 37(6), 70-78.
- SHOAİB, M., BOSCH, S., INCEL, O. D., SCHOLTEN, H., & HAVİNGA, P. J. M. (2016). "Complex human activity recognition using smartphone and wrist-worn motion sensors." **Sensors** (Switzerland), 16(4). doi: 10.3390/s16040426.
- STUART, M., & MANİC, M. (2021). "Deep learning shared bandpass filters for resource-constrained human activity recognition." **IEEE Access**, 9, 39089–39097. <https://doi.org/10.1109/access.2021.3064031>
- TAİ, W., Lİ, X., ZHOU, J., ARİK, S., (2023). "Asynchronous dissipative stabilization for stochastic Markov-switching neural networks with completely- and incompletely- known transition rates." **Neural Networks**, 161, 55-64.
- TAN, Z. VE KARAKÖSE, M. (2022). "Dinamik Ortamlarda Derin Takviyeli Öğrenme Tabanlı Otonom Yol Planlama Yaklaşımları İçin Karşılaştırmalı Analiz." **Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi**, cilt16, ss.248- 262.
- TASNİM, N., ISLAM, M. K., & BAEK, J.-H. (2021). "Deep learning based human activity recognition using spatio-temporal image formation of skeleton joints." **Applied Sciences**, 11(6), 2675. <https://doi.org/10.3390/app11062675>
- THAKUR, D., VE BİSWAS, S. (2021). "Feature fusion using Deep Learning for Smartphone based human activity recognition." **International Journal of Information Technology**, 13(4), 1615–1624. <https://doi.org/10.1007/s41870-021-00719-6>
- TSAİ, C. F. VE WANG, S. P. (2009). "Stock Price Forecasting by Hybrid Machine Learning Techniques." **Proceedings of the International MultiConference of Engineers and Computer Scientists**, sayı 1, ss.755, 760.

WANG, S. AND SUMMERS, R.M., (2012). "Machine learning and radiology." **Medical Image Analysis**, 16(5), 933-951.

YEN, C.-T., LIAO, J.-X., & HUANG, Y.-K. (2021). "Feature fusion of a deep-learning algorithm into wearable sensor devices for human activity recognition." **Sensors**, 21(24), 8294.

## **TEZLER**

AKPINAR, B. (2019). "Görüntü Sınıflandırma İçin Derin Öğrenme ile Bayeşçi Derin Öğrenme Yöntemlerinin Karşılaştırılması", (Yayımlanmamış Yüksek Lisans Tezi). Fen Bilimleri Enstitüsü, Afyon Kocatepe Üniversitesi.

ATBAŞ, A.C. (2008). "Kümeleme Analizinde Küme Sayısının Belirlenmesi Üzerine Bir Çalışma", (Yayımlanmamış Yüksek Lisans Tezi). Fen Bilimleri Enstitüsü, Ankara Üniversitesi.

DOĞAN, M. (2003). "Yapay Sinir Ağları Temelli Tıbbî Teşhis Sistemi", (Yayımlanmamış Yüksek Lisans Tezi), Fen Bilimleri Enstitüsü, Anadolu Üniversitesi.

KARA, İ. (2019). "Borsa Endeksi Hareket Yönünün Tahmininde Sınıflandırma Yöntemlerinin Performanslarının Karşılaştırılması: Bist 100 Örneği", (Yayımlanmamış Yüksek Lisans Tezi), Sosyal Bilimler Enstitüsü, Afyon Kocatepe Üniversitesi.

ÖZKAYNAK, E.. (2013) "Paralel programlama ile ses tanıma işleminin gerçekleştirilmesi." (Yayımlanmamış Yüksek Lisans Tezi), Fen Bilimleri Enstitüsü, Karabük Üniversitesi

TİKEN, C. (2015). "Derin Öğrenme Uygulamaları", (Yayımlanmamış Yüksek Lisans Tezi), Fen Bilimleri Enstitüsü, İstanbul Üniversitesi

KARAATLI, M. (2003). "Yapay Sinir Ağları Yöntemi İle Tahmin (İMKB'de Bir Uygulama)." (Yayımlanmamış Yüksek Lisans Tezi), Sosyal Bilimler Enstitüsü, Süleyman Demirel Üniversitesi

KARAKOYUN, E.Ş. (2018). "Derin Öğrenme ile Zaman Serilerinin Gerçek Zamanlı Tahmini." (Yayımlanmamış Yüksek Lisans Tezi), Fen Bilimleri Enstitüsü, Necmettin Erbakan Üniversitesi.

## **DİĞER KAYNAKLAR**

- ATAŞ, M., OZDEMİR, C., DOĞAN, Y., (2022). "Development of a new autonomous vehicle simulation software with processing", III. International Siirt Scientific Research Congress 18-19 Kasım 2022, Siirt-Türkiye.
- ŞEKER, A. (2017). "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme", Doktora Semineri, FenBilimleri Enstitüsü, Yıldız Teknik Üniversitesi
- TAŞCI, E., & ONAN, A. (2016). "K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi". *Akademik Bilişim*, 1(1), 4-18.
- VAİZMAN, Y., ELLIS, K., LANCKRIET, G., & WEIBEL, N. (2018). "Extrasensory app: Data collection in-the-wild with rich user interface to self-report behavior". *Proceedings of the 2018 CHI conference on human factors in computing systems* (pp. 1-12).
- ZENG, M., GAO, H., YU, T., MENGSHOEL, O. J., LANGSETH, H., LANE, I., & LIU, X. (2018). "Understanding and improving recurrent networks for human activity recognition by continuous attention", *Proceedings of the 2018 ACM international symposium on wearable computers* (pp. 56-63).
- TARASEVIČIUS, D., & SERACKIS, A. (2020). "Deep learning model for sensor based swimming style recognition". *2020 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream)* (pp. 1-4). IEEE.
- YAO, S., HU, S., ZHAO, Y., ZHANG, A., & ABDELZAHER, T. (2017). "DeepSense. In *Proceedings of the 26th International Conference on World Wide Web*", International World Wide Web Conferences Steering Committee.
- KONAK, S., TURAN, F., SHOAİB, M., & DURMAZ, O. (2016). "Feature engineering for activity recognition from wrist-worn motion sensors.", *6th International Joint Conference on Pervasive and Embedded Computing and Communication Systems 2016* (pp. 76-84). SCITEPRESS.

KONGSIL, K., SUKSAWATCHON, J., & SUKSAWATCHON, U. (2019). "Physical activity recognition using streaming data from wrist-worn sensors.", 2019 4th International Conference on Information Technology (InCIT) (pp. 274-279). IEEE.

CHERNBUMROONG, S., ATKINS, A. S., & YU, H. (2011, September). "Activity classification using a single wrist-worn accelerometer.", 2011 5th international conference on software, knowledge information, industrial management and applications (SKIMA) proceedings (pp. 1-6). IEEE.



## ÖZGEÇMİŞ

**Ad-Soyad** : Muhammed Yusuf UYSAL

### ÖĞRENİM DURUMU:

**Lisans** : 2016, Maltepe Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği

**Yüksek Lisans** : 2024, İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı

### MESLEKİ DENEYİM VE ÖDÜLLER:

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

### DİĞER YAYINLAR, SUNUMLAR VE PATENTLER