

**T.C.  
SİİRT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**HAREKET TANIMA İÇİN YEREL İKİLİ ÖRÜNTÜLER TABANLI YENİ BİR  
YAKLAŞIM**

**YÜKSEK LİSANS TEZİ**

**Bahar YAVUZ  
(163111005)**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Dr. Öğretim Üyesi Yılmaz Kaya**

**Mart-2018**

**SİİRT**

## TEZ KABUL VE ONAYI

Bahar Yavuz tarafından hazırlanan "Hareket Tanıma için Yerel İkili Örüntüler Tabanlı Yeni Bir Yaklaşım" adlı tez çalışması 20/03/2018 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Dr. Öğretim Üyesi Ramazan Tekin

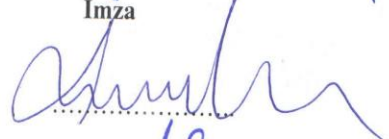


#### Danışman

Dr. Öğretim Üyesi Yılmaz Kaya

#### Üye

Dr. Öğretim Üyesi Melih Kuncan

İmza

Yukarıdaki sonucu onaylarım.

Doç. Dr. Fevzi Hansu  
Fen Bilimleri Enstitüsü Müdürü



## ÖN SÖZ

Bu çalışma boyunca değerli fikirlerini ve desteklerini benden esirgemeyen danışman hocam Sayın Dr. Öğretim Üyesi Yılmaz Kaya'ya ve her daim yanımda olan sevgi ve desteklerini hiç esirgemeyen aileme teşekkürlerimi sunarım.

Bahar YAVUZ  
SİİRT-2018



# İÇİNDEKİLER

## Sayfa

ÖN SÖZ .....	v
İÇİNDEKİLER .....	vi
TABLolar LİSTESİ .....	viii
ŞEKİLLER LİSTESİ .....	x
KISALTMALAR VE SİMGELERLİSTESİ.....	xi
ÖZET .....	xii
ABSTRACT.....	xiii
1. GİRİŞ .....	1
2. LİTERATÜR ARAŞTIRMASI .....	7
3. MATERYAL VE METOT .....	16
3.1. Materyal.....	16
3.2. Metot .....	20
3.2.1. Yerel ikili örüntüler (YİÖ).....	20
3.2.2. Bir boyutlu yerel ikili örüntüler (1B-YİÖ).....	22
3.2.3. Öznitelik çıkarımı .....	25
3.2.3.1. Medyan (Ortanca) .....	25
3.2.3.2. Standart sapma .....	25
3.2.3.3. Varyasyon .....	26
3.2.3.4. Korelasyon .....	26
3.2.3.5. Çarpıklık .....	27
3.2.3.6. Basıklık .....	28
3.2.3.7. Enerji.....	30
3.2.3.8. Entropi .....	30
3.2.4. Çalışma diyagramı.....	30
3.2.5. Sınıflandırma.....	32
3.2.6. Performans ölçütleri .....	33
3.2.6.1. Doğruluk (Accuracy)-Hata oranı (Error rate) .....	33
3.2.6.2. Kesinlik (Precision) .....	34
3.2.6.3. Duyarlılık (Recall) .....	34
3.2.6.4. F-Ölçütü (F-Measure) .....	34

<b>4. BULGULAR.....</b>	<b>35</b>
<b>4.1. 1B-YİÖ Histogramları.....</b>	<b>35</b>
<b>4.2. Başarı Oranları .....</b>	<b>36</b>
<b>4.3. Sensör Türlerine Göre Başarı Oranları.....</b>	<b>40</b>
<b>4.4. Eksenlere Göre Başarı Oranları.....</b>	<b>44</b>
<b>4.5. İstatistiksel Özelliklere Göre Başarı Oranları .....</b>	<b>48</b>
<b>5. TARTIŞMA.....</b>	<b>61</b>
<b>6. KAYNAKLAR .....</b>	<b>65</b>
<b>ÖZGEÇMİŞ .....</b>	<b>69</b>



## TABLolar LİSTESİ

### Sayfa

<b>Tablo 3.1.</b>	Veri kümesinde yer alan aktivite seti.....	16
<b>Tablo 3.2.</b>	Sinyallerin elde edildiđi sensörler.....	19
<b>Tablo 3.3.</b>	Performans Ölçütleri.....	33
<b>Tablo 4.1.</b>	RF sınıflandırma metodu için karışıklık matrisi .....	37
<b>Tablo 4.2.</b>	RF sınıflandırma metodu için performans sonuçları .....	37
<b>Tablo 4.3.</b>	RC sınıflandırma metodu için karışıklık matrisi.....	38
<b>Tablo 4.4.</b>	RC sınıflandırma metodu için performans sonuçları .....	38
<b>Tablo 4.5.</b>	NB sınıflandırma metodu için karışıklık matrisi .....	39
<b>Tablo 4.6.</b>	NB sınıflandırma metodu için performans sonuçları.....	39
<b>Tablo 4.7.</b>	Sınıflandırıcıların performans oranları .....	40
<b>Tablo 4.8.</b>	İvme sensörleri için RC ile elde edilen karışıklık matrisi.....	40
<b>Tablo 4.9.</b>	İvme sensörleri için RC ile elde edilen performans oranları .....	40
<b>Tablo 4.10.</b>	Cayro (Gyro) sensörleri için RC ile elde edilen karışıklık matrisi .....	41
<b>Tablo 4.11.</b>	Cayro (Gyro) sensörleri için RC ile elde edilen performans oranları....	41
<b>Tablo 4.12.</b>	Manyometre (Magnetometer) sensörleri için RC ile elde edilen karışıklık matrisi .....	42
<b>Tablo 4.13.</b>	Manyometre (Magnetometer) sensörleri için RC ile elde performans oranları .....	42
<b>Tablo 4.14.</b>	EEG işaretleri için RC ile elde edilen karışıklık matrisi.....	43
<b>Tablo 4.15.</b>	EEG işaretleri için RC ile elde edilen performans oranları .....	43
<b>Tablo 4.16.</b>	Kullanılan sensörlerin sınıflandırmadaki toplam başarı oranları.....	44
<b>Tablo 4.17.</b>	Sensörlerin X ekseninden elde edilen öznelikler ile gözlenen karışıklık matrisi .....	44
<b>Tablo 4.18.</b>	Sensörlerin X ekseninden elde edilen özneliklerin performans oranları .....	45
<b>Tablo 4.19.</b>	Sensörlerin Y ekseninden elde edilen öznelikler ile gözlenen karışıklık matrisi .....	45
<b>Tablo 4.20.</b>	Sensörlerin Y ekseninden elde edilen özneliklerin performans oranları .....	46
<b>Tablo 4.21.</b>	Sensörlerin Z ekseninden elde edilen öznelikler ile gözlenen karışıklık matrisi .....	46
<b>Tablo 4.22.</b>	Sensörlerin Z ekseninden elde edilen özneliklerin performans oranları .....	47
<b>Tablo 4.23.</b>	Eksenlere göre başarı oranları.....	47
<b>Tablo 4.24.</b>	Ortalama öznelikleri için NB ile elde edilen karışıklık matrisi .....	48
<b>Tablo 4.25.</b>	Ortalama öznelikleri için NB ile elde edilen performans oranları.....	48
<b>Tablo 4.26.</b>	Standart sapma öznelikleri için NB ile elde edilen karışıklık matrisi .	49
<b>Tablo 4.27.</b>	Standart sapma öznelikleri için NB ile elde edilen performans oranları .....	49
<b>Tablo 4.28.</b>	Enerji öznelikleri için NB ile elde edilen karışıklık matrisi .....	50
<b>Tablo 4.29.</b>	Enerji öznelikleri için NB ile elde edilen performans oranları.....	50
<b>Tablo 4.30.</b>	Entropi öznelikleri için NB ile elde edilen karışıklık matrisi .....	51
<b>Tablo 4.31.</b>	Entropi öznelikleri için NB ile elde edilen performans oranları .....	51
<b>Tablo 4.32.</b>	Korelasyon öznelikleri için NB ile elde edilen karışıklık matrisi .....	52
<b>Tablo 4.33.</b>	Korelasyon öznelikleri için NB ile elde edilen performans oranları ...	52
<b>Tablo 4.34.</b>	Ardışık mutlak farklar öznelikleri için NB ile elde edilen karışıklık matrisi .....	53

<b>Tablo 4.35.</b> Ardışık mutlak farklar öznitelikleri için NB ile elde edilen performans oranları .....	53
<b>Tablo 4.36.</b> Medyan öznitelikleri için RF ile elde edilen karışıklık matrisi .....	54
<b>Tablo 4.37.</b> Medyan öznitelikleri için RF ile elde edilen performans oranları .....	54
<b>Tablo 4.38.</b> Çarpıklık öznitelikleri için RF ile elde edilen karışıklık matrisi .....	55
<b>Tablo 4.39.</b> Çarpıklık öznitelikleri için RF ile elde edilen performans oranları .....	56
<b>Tablo 4.40.</b> Basıklık öznitelikleri için Çok Katmanlı Algılayıcı ile elde edilen karışıklık matrisi .....	56
<b>Tablo 4.41.</b> Basıklık öznitelikleri için NB ile elde edilen performans oranları .....	57
<b>Tablo 4.42.</b> Minimum öznitelikleri için RF ile elde edilen karışıklık matrisi.....	57
<b>Tablo 4.43.</b> Minimum öznitelikleri için RF ile elde edilen performanslar .....	57
<b>Tablo 4.44.</b> Maximum öznitelikleri için NB ile elde edilen karışıklık matrisi .....	58
<b>Tablo 4.45.</b> Maximum öznitelikleri için NB ile elde edilen performanslar .....	58
<b>Tablo 4.46.</b> Varyasyon Katsayısı öznitelikleri için NB ile elde edilen karışıklık matrisi .....	59
<b>Tablo 4.47.</b> Varyasyon Katsayısı öznitelikleri için NB ile elde edilen performanslar .....	59
<b>Tablo 4.48.</b> Özelliklere göre başarı oranları.....	60

## ŞEKİLLER LİSTESİ

**Sayfa**

<b>Şekil 3.1.</b>	Çalışmada kullanılan örnek sinyaller (a) L1 hareketine ait sinyal, (b) L2 hareketine ait sinyal, (c) L3 hareketine ait sinyal, (d) L4 Hareketine ait sinyal, (e) L5 hareketine ait sinyal, (f) L6 hareketine ait sinyal, (g) L7 hareketine ait sinyal, (h) L8 hareketine ait sinyal, (ı) L9 hareketine ait sinyal, (i) L10 hareketine ait sinyal, (j) L11 hareketine ait sinyal, (k) L12 hareketine ait sinyal.....	18
<b>Şekil 3.2.</b>	Farklı YİÖ operatörleri için dairesel simetrik komşu kümeleri .....	21
<b>Şekil 3.3.</b>	YİÖ kodunun hesaplanması .....	22
<b>Şekil 3.4.</b>	Ayakta durma pozisyonu olan L1 hareketinden elde edilmiş olan ECG sinyallerinden 1B-YİÖ kodu hesaplama.....	23
<b>Şekil 3.5.</b>	Sinyal üzerindeki örnek değerler.....	23
<b>Şekil 3.6.</b>	Pc ve Pi komşu değerlerinin karşılaştırılması (Denklem (3.1)'in uygulanması).....	24
<b>Şekil 3.7.</b>	İkili dizgeden elde edilen 1B-YİÖ kodu .....	24
<b>Şekil 3.8.</b>	Sinyalden elde edilmiş olan 1B-YİÖ kodu.....	24
<b>Şekil 3.9.</b>	Farklı korelasyon durumları .....	27
<b>Şekil 3.10.</b>	Çarpıklık katsayısı ( $\text{ÇK}$ ) = 0 olduğu durumda dağılım simetrik olmaktadır .....	28
<b>Şekil 3.11.</b>	Çarpıklık katsayısı ( $\text{ÇK}$ ) < 0 olduğu durumda dağılım sola çarpık yada (-) yöne eğilimli olmaktadır .....	28
<b>Şekil 3.12.</b>	Çarpıklık katsayısı ( $\text{ÇK}$ ) > 0 olduğu durumda dağılım sağa çarpık yada (+) yöne eğilimli olmaktadır .....	28
<b>Şekil 3.13.</b>	BK = 0 ise dağılımın yüksekliği standart normal dağılıma uygundur. ...	29
<b>Şekil 3.14.</b>	BK < 0 ise dağılım standart normal dağılımdan daha basıktır .....	29
<b>Şekil 3.15.</b>	BK > 0 ise dağılım standart normal dağılımdan daha sivridir .....	29
<b>Şekil 3.16.</b>	Önerilen yöntemin blok şeması .....	31
<b>Şekil 4.1.</b>	Uzanma aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı.....	35
<b>Şekil 4.2.</b>	Öne eğilme aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı .....	35
<b>Şekil 4.3.</b>	Bisiklet sürme aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı.....	36
<b>Şekil 4.4.</b>	Öne arkaya zıplama aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı .....	36



## KISALTMALAR VE SİMGELERLİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
<b>HT</b>	: Hareket Tanıma
<b>HS</b>	: Hareket Sensörleri
<b>YİÖ</b>	: Yerel İkili Örüntü
<b>1B-YİÖ</b>	: Bir Boyutlu Yerel İkili Örüntü Modeli
<b>1D-LBP</b>	: One Dimensional Local Binary Pattern Model
<b>EEG</b>	: Elektroensefalografi
<b>HS</b>	: Hareket Sensörleri
<b>MEMS</b>	: Microelectromekanic Systems
<b>EMG</b>	: Elektromiyografi
<b>ALS</b>	: Amyotrofik Lateral Skleroz
<b>DMM</b>	: Derinlik Hareket Haritaları
<b>SVM</b>	: Support Vector Machine
<b>EM-ÇKF</b>	: Expectation Maksimizasyon-Çok Yönlü Konik Fonksiyonlar
<b>EKG</b>	: Elektrokardiyografi
<b>OSELM</b>	: Online Sequential Extreme Learning Machine
<b>SLFN</b>	: Elektrokardiyografi
<b>AHN</b>	: Yapay Hidrokarbon Ağı
<b>PAMAP2</b>	: Physical Activity Monitoring Dataset
<b>ANN</b>	: Artificial Neural Network
<b>KNN</b>	: K-Nearest Neighbour
<b>PCA</b>	: Princibal Component Analyses
<b>ICA</b>	: Indepent Component Analyses
<b>MRMR</b>	: Minimum Redundancy and Maximum Relevance
<b>FCBF</b>	: Hızlı Korelasyona Dayalı Filtre Yöntemi
<b>AQ</b>	: Kuaterniyon Hızlanma Yöntemi
<b>AAR</b>	: İvmeye Dayalı Hızlanma Yöntemi
<b>GMM</b>	: Gauss Mixture Model
<b>MHEALTH</b>	: Mobile Health
<b>CV</b>	: Varyasyon Katsayısı
<b>ÇK</b>	: Çarpıklık Katsayısı
<b>BK</b>	: Basıklık Katsayısı
<b>HO</b>	: Hata Oranı
<b>NB</b>	: Naive Bayes
<b>RC</b>	: Random Commitee
<b>RF</b>	: Random Forest
<b>WEKA</b>	: Waikato Environment for Knowledge Analysis

<u>Simge</u>	<u>Açıklama</u>
$\sigma$	: Standart sapma
$\bar{x}$	: Aritmetik ortalama

## ÖZET

### YÜKSEK LİSANS TEZİ

## HAREKET TANIMA İÇİN YEREL İKİLİ ÖRÜNTÜLER TABANLI YENİ BİR YAKLAŞIM

**Bahar YAVUZ**

**Siirt Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Danışman : Dr. Öğretim Üyesi Yılmaz KAYA**

**2018, 68 Sayfa**

İnsan vücudunun hareketini algılayan ve takip eden en önemli teknoloji, sensör tabanlı hareket tanıma teknolojisidir. Son yıllarda sensör tabanlı insan hareketi tanıma, günlük yaşamdaki geniş kullanımı nedeniyle bilgisayar alanında gözleri üzerine çekmektedir ve hızla büyüyen bir araştırma alanı olmuştur. Hareket tanıma, insan vücuduna yerleştirilmiş çeşitli sensörlerden elde edilen sinyallerin değerlendirilmesi ile gerçekleştirilmektedir. Hareket tanıma sistemlerinin başarısı, sinyallerden elde edilen özniteliklere bağlıdır. İşaretlerden uygun ve etkin özniteliklerin çıkarılması sınıflandırma doğruluğunu etkilemektedir. Bu çalışmada, sensör işaretlerinden etkin öznitelikler elde etmek için, yeni bir yaklaşım yöntemi önerilmiştir. Bu yöntem, bir boyutlu yerel ikili model (1B-YİÖ), sinyal üzerindeki bir değer belirlenir bir komşuluk değerine göre merkezdeki örneğin değeri baz alınarak sağ ve sol komşularının karşılaştırılmaları sonucunda yeni bir ikili değer elde edilmesi ve bu ikili değer onlu bir değere dönüştürülmesi işlemidir. Bu yöntem, çeşitli non-parametrik sinyallerden etkili öznitelikler elde edilmesini sağlayan bir istatistiksel metottur. Önerilen metodu test etmek için on gönüllünün on ikişer fiziksel aktivitelere ait sinyaller kullanılmıştır. İvme, cayro ve manyometre sensörlerinden elde edilen işaretlere 1B-YİÖ yöntemi uygulandıktan sonra, yeni oluşan işaretlerden birtakım istatistiksel öznitelikler çıkarılmıştır. Bu istatistiksel öznitelikleri kullanarak farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Bu çalışmada hareket tanıma başarısı üzerinde; sensör türlerinin, sensör eksenlerinin ve çıkarılan istatistiksel özniteliklerin etkisi de araştırılmıştır. Gerçekleştirilen tüm denemelerde en yüksek başarı %92,5 olarak gözlenmiştir.

**Anahtar Kelimeler:** Hareket tanıma, Öznitelik çıkarımı, Yerel ikili örüntüler

## **ABSTRACT**

### **MSc THESIS**

## **A NOVEL APPROACH FOR ACTIVITY RECOGNITION BASED ON LOCAL BINARY PATTERNS**

**Bahar YAVUZ**

**The Graduate School of Natural and Applied Science of Siirt University  
The Degree of Master of Science  
in Electrical-Electronics Engineering**

**Supervisor : Ass. Prof. Yılmaz KAYA**

**2018, 68 Pages**

The most important technology that perceives and follows the movement of the human body is sensor based motion recognition technology. In recent years, sensor-based human motion recognition has attracted attention in the computer field due to its widespread use in everyday life and is a rapidly growing field of research. Motion recognition is performed by evaluating signals from various sensors placed in the human body. The success of motion recognition systems depends on the attributes obtained from the signals. The extraction of appropriate and effective attributes from the signals affects the accuracy of classification. In this work, a new approach has been proposed to obtain effective attributes from sensor signals. This method, One Dimensional Local Binary Pattern Model (1D-LBP) is a process for obtaining a new binary value as a result of comparison of the right and left neighbors based on the center sample value according to a certain neighborhood value of a value on the signal, and transforming the binary value into a decimal value. This method is a statistical metric that enables effective attributes to be obtained from various non-parametric signals. To test the proposed method, the signals of twelve physical activities of ten volunteers were used. A number of statistical attributes have been derived after applying the 1D-LBP method to the signals obtained from acceleration, gyro and magnetometer sensors. By using these statistical attributes, different machine learning methods and classifications have been performed. In this study, on the success of motion recognition; the effects of sensor types, sensor axes and extracted statistical attributes were also investigated. The highest success rate was %92,5 in all experiments.

**Keywords:** Attribute extraction, Local binary patterns, Motion recognition

## 1. GİRİŞ

Fiziksel aktivitelerin otomatik tanınması genelde, Hareket Tanıma (HT) olarak ifade edilir. HT, insan-bilgisayar etkileşiminde anahtar bir araştırma alanı olarak ortaya çıkmıştır. HT sistemleri, kişinin vücuduna bağlı heterojen sensörleri kullanarak ve insan eylemlerinin durumunu yansıtan birçok fizyolojik sinyalin sürekli izlenmesine izin vererek kullanıcının ve çevresinin durumunu yakalamayı hedeflemektedir.

HT için genellikle EEG, ivmeölçerler, jiroskoplar, manyometreler gibi vücuda takılabilen hareket sensörleri kullanılmaktadır. İvmeölçerler; hassas bir eksende hareket eden ivmeyi ölçen sensörlerdir. Jiroskoplar; hassas bir eksen etrafında dönme oranını ölçen sensörlerdir. Manyometreler; manyetik sensörlerdir ve hassas bir eksen boyunca yerel manyetik alanın bileşenlerini ölçerler. EEG (Elektroensefalografi) beyindeki elektriksel aktiviteyi değerlendirmek için kullanılan işaretlerdir.

Hareket sensörleri (HS), konumlandırıldıkları vücut bölümünün hareketi ile doğrudan ilişkili olan fiziksel niceliklerin ölçülmesine dayalı olarak konum ve yönlendirme bilgilerini belirlemeyi mümkün kılmaktadırlar. HS hemen hemen sınırsız çalışma alanında vücut hareketini algılamak ve izlemek için kullanılmaktadırlar. HS, günümüze kadar yalnızca uçaklar, gemiler, denizaltılar, arabalar ve daha yakın zamanda, tekerlekli ve bacaklı robotlar dahil olmak üzere insan yapımı araçların hareketini izlemek için kullanılmaktaydı. Fakat Mikroelektromekanik sistemlerdeki (MEMS) son gelişmeler; yeni nesil hareket sensörlerinin (Bachman ve ark., 2003) gelişimine yol açmıştır.

Hareketleri ve eylemleri analiz etmek uzun bir geçmişe sahiptir ve psikoloji, biyoloji ve bilgisayar bilimi gibi çeşitli disiplinlerle etkileşim içerisindedir. Son yıllarda, sensör temelli insan HT, günlük yaşamdaki geniş kullanımı nedeniyle bilgisayar bilimi alanında önemli bir rol oynamaktadır. Hareket ve duruşun değerlendirilmesi ve genel olarak davranışın kinematik analizi için sensör teknolojisindeki ilerlemeden ve sinyal analizindeki ileri yöntemlerden büyük ölçüde yararlanılmaktadır. Gömülü sensörlere sahip giyilebilir cihazların geliştirilmesiyle birlikte, kullanıcının ihtiyaçlarını anlamak ve kişiselleştirilmiş hizmetler sunmak için analiz edilebilecek verileri toplamak mümkün hale gelmiştir. Bir kişinin durumunu tanıyabilmek, bize diğer sistemler için girdi olarak kullanılacak değerli bilgiler sağlar duruma gelmiştir.

İnsan HT araştırma alanı, sağlık, ofis senaryoları, eğitim, robotik, sanayi sektörü (Maurtua ve ark., 2007; Stiefmeier ve ark., 2008), akıllı evler (Rashidi ve Cook,

2009), eğlence sektörü (Kunze ve ark., 2006; Minnen ve ark., 2006; Ladha ve ark., 2013) gibi birçok sektörde birçok yenilikçi uygulama ile son yıllarda hızla genişlemiştir (Bao ve Intille, 2004; Tapia ve ark., 2004; Ravi ve ark., 2005; Logan ve ark., 2007).

Robotikte HT, insanlarla robotlar arasındaki doğal etkileşimi kolaylaştırmaktadır. Robotik araştırmalarındaki gelişmeler, robotları gerçek dünya uygulamalarına daha yakın hale getirmektedir. Robotların, kullanıcıların bir sonraki adımlı hareketlerini anlaması ve tahmin etmesi ve kullanıcılara uygun bir yanıt vermesi gerekmektedir. Bu nedenle, insan aktivite ve faaliyetlerinin erken tanınması insan-robot etkileşiminde çok önemlidir.

Spor ve boş zamanlardaki uygulamalar için, giyilebilir sensörleri kullanan sayısız hareket tanıma sistemlerinin önerildiği bilinmektedir. Buna; günlük ve spor aktivitelerinin tanınması, spor faaliyetlerinin izlenmesi; dövüş sanatlarında dövüş eğitiminde etkileşimi artırmak için dövüş sanatlarındaki hareket dizilerinin belirlenmesi gibi örnekler verilebilir (Avcı ve ark., 2010).

Eğlence alanında HT, akıllı televizyonlar ve oyun konsolları ile daha sezgisel ve doğal etkileşim için dokunmatik etkileşimi sağlamaktadır. Bu etkileşimli uygulamaların kilit bir gereksinimi, eylemlerin gerçek zamanlı olarak sağlam bir şekilde tespit edilebilmesidir, böylece sistem görünür bir gecikme olmadan kullanıcıya uygun bir yanıt sağlayabilmektedir. Son zamanlarda HT, birçok tüketici ürünüde kilit bir bileşen olarak ilk kez yerini almıştır. Örneğin, Nintendo Wii ve Microsoft Kinect gibi oyun konsolları, oyun deneyimini kökünden değiştirmek için jestlerin veya hatta tüm vücut hareketlerinin tanınmasına dayanmaktadır. Başlangıçta eğlence sektörü için geliştirilmiş olsa da, bu sistemler kişisel fitness eğitimi ve rehabilitasyon gibi ek uygulamalar bulmuş ve ayrıca yeni HT araştırmalarını teşvik etmiştir (Sung ve ark., 2011). Philips DirectLife veya Nike koşu ayakkabıları gibi bazı spor ürünleri, hareket sensörlerini bütünleştirip ve performanslarıyla ilgili hem amatör hem de profesyonel sporcuların geri bildirimlerini sunmaktadır.

Gelişmiş ülkelerdeki toplumlar hızla yaşlanmaktadır. 2030 yılına gelindiğinde, toplam yaşlı kişinin bir milyara yükseleceği tahmin edilmektedir. Yaşlanan nüfusun en hızlı artışı gelişmekte olan ülkelerde gerçekleşmekte ve 2030 yılına kadar %140'lık bir sıçrama öngörülmektedir. Ayrıca, 2050 yılına kadar dünya nüfusunun 9,3 milyara ulaşması beklenmektedir ve 60 yaşın üzerindeki insanlar nüfusun %28'ini oluşturacaktır (Akgün ve ark., 2004; Chernbumroong ve ark., 2013). İnsan

yaşam beklentisinin 2100 yılına kadar 81 yıla ulaşması beklenmekte olup, giderek artan yaşam maliyetini desteklemek için devasa mali kaynaklara ihtiyaç duyulması beklenmektedir. Yaşlı insanların vücut işlevleri bozukluklarına veya yaşla ilişkili hastalıklara maruz kalmaları, akıllı sağlık yardım sistemlerine gereksinimi her yıl artırmaktadır. Geriyatrik hastaları (65 yaş üstü hastalar) izlemenin en yaygın yöntemi, fiziksel gözlemlerdir. Fakat masraflı, çok sayıda personel gerektiren ve ilerleyen yıllarda kitlesel nüfus yaşlanması açısından, uygulama bakımından giderek zorlaşmaktadır. İnsan-bilgisayar etkileşim teknolojileri gibi birçok yaşam destek uygulaması; insan hareketlerinin tanınmasını gerektirmektedir. Yaşam destek uygulamalarına öncelikli olarak ihtiyaç duyanlar yaşlılar iken, zihinsel ve fiziksel olarak engelliler, ayrıca diyabet ve obezite çeken, evde yardıma ihtiyacı olan herhangi yaştaki bir insan için de geçerlidir.

Giyilebilir sensörleri kullanarak insan HT, rehabilitasyon uzmanlarına hasta hareketliliği hakkında değerli bilgiler verme potansiyeline sahip büyümekte olan bir alandır. Evde bağımsız yaşamı desteklemek için sensör tabanlı izleme sistemleri, son yıllarda birçok kişinin ilgisini çekmektedir.

HT sistemleri; anormal durumları tespit etmek veya öngörülemeyen olayları önlemek için aktivitelerin sürekli olarak izlenmesine ihtiyaç duymaktadırlar. Sağlık izleme cihazlarının yeni teknolojileri, vücut tarafından giyilebilmektedir. Gelişen sensör teknolojisiyle beraber biyo-sensörler, genellikle Elektrokardiyografi (EKG), Elektromiyografi (EMG), kan basıncı, kalp atış hızı ve sıcaklık gibi hayati bulguları izlemek için nöbetler, hipertansiyon, distimya ve astım gibi hastalıklar fizyolojik izleme ile teşhis ve tedavi edilebilmektedir. Hastane ortamında da hastaların hareket takiplerinin yapılması çok önemlidir. Çünkü yatar durumda olan hastaların yanlış hareketler yaparak sakıncalı hareketlerde bulunmaları yüzünden iyileşme süreleri uzamaktadır.

HT; ayrıca bir hastane ortamının dışında izlenen kişilerin sağlığı ve esenliği hakkında değerli bilgiler sağlayabilen hızla büyüyen bir araştırma alanı olmaktadır. Giyilebilir teknolojiyi kullanarak günlük aktivitenin tanınması sağlık alanında önemli bir rol oynamaktadır. Bununla birlikte uyku, yemek pişirme ve yemek yeme gibi günlük yaşantı aktivitelerini izlemek, yaşlıların ve engellilerin evde bağımsız olarak yaşamasına yardımcı olabilir ve anormal durumu en kısa zamanda tespit etmek, tehlikeyi minimum ölçüde azaltabilmektedir. Biri tehlikeli bir hareket yapmaya başladığında tespit ederek

güvenlik riskini azaltmak için uyarı veren güvenlik uygulamaları yer almaktadır (Patel ve ark., 2012).

Giyilebilir sensörleri kullanarak insan aktivitelerinin tanınması; cihazların düşük maliyetli, küçük boyutlu ve düşük enerji tüketimi sayesinde günlük aktiviteleri; rahatsız etmeden elde edilmesine olanak sağlamaktadır.

Kişinin hareketleri ile ilgili kesin bilgileri kaydetmek ve analiz etmek, hastalığın (veya zihinsel durumun) ilerlemesini ve durumunu korumak için faydalı olup kişilerin hastalıklarını iyileştirmenin yanı sıra bakım masraflarını da düşürebilmektedir. İç ve dış mekân aktivitelerini tanıma; yürüme, koşu ya da bisiklet gibi, bakım yapan görevlinin hastanın davranışları hakkında geri bildirim alması yararlı olabilmektedir. HT teknolojisi; yaşlı, hasta ve zihinsel rahatsızlıklara sahip insanlara evde bağımsız yaşama imkânı verebilmektedir. Dahası; HT sistemleri, kullanıcıların davranışlarını ve yaşam biçimlerini daha aktif ve daha sağlıklı hale getirmek için tasarlanabilmektedir.

Ünlü fizikçi Stephen Hawking daha 21 yaşındayken ALS (Amyotrofik lateral skleroz) hastalığına yakalanmıştır. Zamanla hareket yeteneğinin tamamını kaybeden Hawking; yaşarken sadece yanağında hareket ettirebildiği bir kasını kullanarak İntel'in tasarladığı gelişmiş akıllı yürüme destekli sisteme komut verebilmekteydi. Yüzündeki bu kasın hareketiyle ve göz hareketleriyle önündeki bilgisayar ekranıyla etkileşim halinde, konuşmak ve yazmak istediklerini aktarabilmekteydi. Dolayısıyla hareket tanıma; tüm yönleriyle insanlık için hayati bir önem arz etmektedir.

HT sistemleri; toplantıya katılmak, kahve içmek veya masada çalışmak gibi ofis çalışanlarının faaliyetlerini tespit ederek, bu farklı koşullara bağlı olarak telefon görüşmelerini filtreleme kapasitesine sahip akıllı bir sisteme sahip bir cep telefonuna da imkân verilebilen uygulamalar gerçekleştirebilmektedir. İnsan HT, akıllı mobilya, servis robotu ve akıllı gözetim gibi birçok uygulamada son derece önemli bir rol oynamaktadır. Bahsedilen uygulamaların hepsini gerçekleştirmede hareket tanımanın önemi büyüktür, yapılabilir uygulamalardır. Bu örneklerin tümü hem akademik hem de endüstriyel alanda insan hareketi tanımanın önemini vurgulamaktadır. Vücudundaki atalet sensörlerinden aktivitelerin çıkarılmasına ve aktivite tanıma sistemlerinin prototip ve konuşlandırılmasına yönelik önemli gelişmelere rağmen, uygulama ve kullanıcı gereksinimlerini karşılayan HT sistemlerini geliştirme, zorlu bir görev olmaya devam etmektedir.

Bir başka uygulama senaryosu, kullanıcının mevcut etkin aktivitesini algılayan ve aktivite için uygun belirli bir müzik türünü öneren içeriğe duyarlı müzik tavsiyesidir (Wang ve ark., 2012).

Aktivite tanıma için tipik sinyal işleme adımları, sinyali elde etme, öznitelik çıkarma, boyut azaltma (özellik seçimi) ve sınıflandırmadır. Bir sinyalden çok sayıda özellik çıkarılabilirken, özelliklerin sayısını artırmak, sınıflandırıcının doğruluğunu mutlaka artırmaz; çünkü özelliklerden bazıları gereksiz ve alakasız olabilmektedir. Böylece, özellik seçimi, veri boyutsallığını azaltmak ve alakalı ve kullanışlı özellikleri sınıflandırıcıya iletmek için kullanılabilir. Özellik seçimi, potansiyel olarak büyük boyutlu veri boyutunu azaltmak, boyutsallık konusu ile düzgün bir şekilde baş etmek için ve aktivite sınıflandırmasını etkinleştirmek için uygun parametreleri sağlamak için önemli bir adımdır. Başarılı özelliklerin seçilmesi, modellerin daha kolay yorumlanmasını, model eğitim sürelerinin azaltılmasını ve sınıflar arasındaki farkın daha iyi anlaşılmasını kolaylaştırmaktadır. Özellik seçimi; sınıflandırma doğruluğunu olumsuz yönde etkilemeksizin gereksiz veya alakasız özelliklerin kaldırılmasına olanak tanımaktadır. Tipik bir özellik seçimi yönteminde dört temel adım vardır, bunlar; aday özellik alt kümesinin oluşturulması, özellik aday alt kümesi için bir değerlendirme fonksiyonu, durdurma kriterleri ve bir doğrulama prosedürüdür. İyi özniteliklerin seçimi hareket tanımda temel bir adımdır ve çok problemlidir. Fiziksel aktivite sinyallerinden çok sayıda özellik çıkarılabilir de özelliklerin fazlalığı olabilmektedir veya sınıflara özel olmayabileceğinden, özellik sayısının artırılması mutlaka sınıflandırma doğruluğunu arttırmamaktadır.

Hareket tanıma alanında yüksek hesaplama maliyetlerinden, fazla boyutluluktan ve ilgisiz özelliklerden kaçınmak için uygun bir öznitelik kümesi gereklidir. Öznitelik alanı boyutunun azaltılması, sınıflandırma performansını artırmaktadır. Bu nedenle HT algoritmasının geliştirilmesine rehberlik etmek için anlamlı bilgilerin çıkarılması gerekmektedir.

Bu çalışmada, özellik boyut redüksiyonuna dayanan günlük insan faaliyetlerinin çevrimdışı tanınması için yeni bir metod yer almaktadır. Çalışmanın özelliği; belli başlı hareketleri sınıflandırmak için literatürde olmayan yeni bir öznitelik çıkarım yöntemi önerilmesidir.

Bu çalışmada sensörlerden alınan sinyal değerleri on gönüllüden alınmış olan belirli hareketler esnasında sensörlerin kaydettiği değerlerden oluşmaktadır. Toplamda



on iki hareketin (hareketsiz durma, oturma ve rahatlama, uzanma, yürüme, merdiven tırmanma, belin öne eğilmesi, kolları yukarı kaldırma, dizlerin bükülmesi (çömelme), bisiklet sürme, tempolu yürüyüş, koşma ve zıplama) tanınması amaçlanmıştır. Her gönüllü bu on iki hareketi gerçekleştirmiştir. Veri kümesi UCI veri tabanından alınmıştır. Bu veri seti Mhealth ismi ile HT sistemleri için paylaşılmıştır.



## 2. LİTERATÜR ARAŞTIRMASI

Makine öğrenme yöntemleriyle hareket tanıma tahmini yaklaşık son on yılda büyük bir ilgi uyandırmış ve farklı fiziksel aygıtlar ve akıl yürütme teknikleri kullanan birçok araştırma grubu tarafından ele alınmıştır.

HT görevini yerine getirmek için iki ana yaklaşım kullanılmakta olup bunlar; vizyon temelli (bilgisayarla görme) yaklaşım ve sensör (algılayıcı) tabanlı yaklaşımdır. Bilgisayarla görme yaklaşımı; senaryoya yerleştirilen video kamera kullanımına dayanmaktadır. Kameralar üzerinden elde edilen görüntülerden HT gerçekleştirilmektedir. Bu tür HT'da birden fazla kameradan alınan veriler görüntü işleme teknikleri ile aktiviteleri tanımlamaktadır. Bu yaklaşımda giyilebilir sensörlere gerek yoktur, ancak görüntü kalitesine ve ortamın aydınlatma değerine ve görüntülerin elde edildiği açıya bağlıdır. Genellikle laboratuarda çalışır ancak gerçek dünya senaryolarında dağınıklık, değişken ışık yoğunluğu ve kontrasttan dolayı başarısız olabilmektedir. Bilgisayarla görmeye dayalı HT sistemleri; bir veya birden fazla kamera, bir özellik çıkarma modülü ve bir hareket sınıflandırma modülünden oluşmaktadır. Özellik çıkarım aşamasında gerekli özellikler kamera veya kameraların yakaladıkları görüntülerden elde edilmektedir. Özellik çıkarımı üç alt kategoriye ayrılmaktadır; genellikle üç boyutlu modellere kamera ve video kaydı yapılarak derinlik sensörü yardımıyla elde edilen verilerden çıkarılabilen özniteliklerdir. Derinlik Hareket Haritalarından (DMM) hesaplanan histogramlar, derinlik görüntülerinden vücut şeklini ve hareket bilgilerini yakalamak için kullanılmaktadır.

Dardas ve Georganas (2011), çalışmalarında bir görüntünün içerisindeki elin tespiti için çalışmalar yapmışlardır. Görüntüdeki elin hareketlerini tespit ederek, hareketin bir video oyun uygulamasının kontrolünü sağlamasını yani komut vermesini amaçlamışlardır. Çok Katmanlı Destek Vektör Makinesi (SVM) aracılığıyla el hareketlerini tanıma ve harekete geçirme komutları üreten bir dilbilgisi oluşturma yoluyla dağınık arka planda çıplak el bulma ve izleme özelliğini içeren bir sistem amaçlamışlardır. Bir web kameradan el hareketlerinin yakalanıp daha sonra kendi algoritmalarının uygulanarak sınıflandırmanın yapılmasını sağlamışlardır. Kullandıkları algoritmaları gerçek zamanlı olarak kullanmışlardır, bunun diğer HT uygulamalarından üstünlüğünü belirtmişlerdir.

Çimen (2013), tez çalışmasında hareket tanıma işleminin sınıflandırma aşaması

üzerinde durmuştur. Çalışmasında kameradan alınan görüntülerden yararlanmıştır. Çeşitli el hareketleri ile sınıflandırma aşamasında geliştirdiği bir kümeleme algoritması olan EM-ÇKF (expectation maksimizasyon-çok yönlü konik fonksiyonlar) ve üzerinde çalıştığı bütünsel k-ort-ÇKF (çok yönlü konik fonksiyonlar) algoritmasını kullanarak sınıflandırmayı gerçekleştirmiştir. Kümelemeye dayalı yöntemlerin hareket tanıma için kıyaslanmasını yapmıştır, geliştirdiği yöntemin iyi sonuçlar elde etmesi fakat yavaş olması nedeniyle uygulamada pratikliği tartışılmıştır.

HT alanında giyilebilir sensör temelli yaklaşımda ise insanların kendilerini nasıl hareket ettirdiklerini veya nesnelere nasıl hareket ettirdiklerini algılamak için kişinin vücudunun farklı noktalarına sensörler yerleştirilir. Hareket ve duruşun değerlendirilmesi genel olarak, davranışın kinematik analizi, sensör teknolojisindeki ilerlemeden ve sinyal analizinde ileri yöntemlerden büyük ölçüde yararlanmıştır. Bir insan hareketini giyilebilir sensör temelli bir yaklaşımla tanımak için; hareketin fiziksel ortamda mevcut olması, sensörlerin hareketten etkilenen çevrenin fiziksel parametrelerinin güvenilir bir temsilini sağlaması ve bir sınıflandırma algoritmasının bu aktiviteyi doğru bir şekilde tanıması gerekmektedir. Sınıflandırmayı gerçekleştirmek için geniş bir veri setinden ve çeşitli koşullarda alınan hareketler karar sınırlarını belirlemek için kullanılabilir. Farklı hareketler; ani değişikliklere uğramadıkları için tespit edilmeleri daha zor olabilmektedir. Bir de bu aktivitelerin insanlar tarafından gerçekleştirilirken değişkenlik oranı da yüksek olmaktadır. Basit sensörlerden alınan bilgi miktarı sınırlı ve gürültülü olabilmektedir. Sensör teknolojisi; HT aşamasında başarıya etki eden önemli bir adımdır. HT kapsamında giyilebilir sensörler kullanılarak çevresel özellikler, ivme, yer bilgisi ve fizyolojik özellikler gibi dört özellik grubu ölçülebilmektedir. Fizyolojik sinyaller; yaşamsal bulguları ölçen sensörlerden elde edilen sinyallerdir. Bunlar; kalp hızı, solunum hızı, deri sıcaklığı, cilt iletkenliği, EKG, vb. olabilmektedir.

Çevresel sensörlere genellikle ivme ölçerler ve diğer sensörler eşlik etmektedir. İvme ölçerler; hareket tanıma için belki de en yaygın olarak kullanılan sensör türü olmaktadır (ör. yürüme, koşma, uzanma vb.). İvme ölçerler düşük maliyetli ve nispeten düşük güç gerektirmektedirler. Ayrıca bugünün cep telefonlarının çoğunda gömülü olarak yer almaktadırlar. Bu yüzden literatürde sıkça kullanıldıkları görülmektedir.

Tural ve Akdoğan (2017); çalışmalarında, akıllı telefonların algıyıcılarından

alınan verileri kullanarak yapay sinir ağı ile insan hareketlerinin sınıflandırmasını gerçekleştirmişlerdir. Çalışmalarında içinde 3-eksenli ivme ölçer ve jiroskop bulunan bir akıllı telefon ile insan hareketi algılama sistemi geliştirmişlerdir. Bu sistemde, algılayıcılardan gelen bilgiler daha sonra sınıflandırılarak kişinin hareketi tahmin edilmektedir. Veri setinde otuz gönüllüye ait altışar hareket bulunmaktadır (ayakta durma, yere uzanma ve oturma, yürüme, merdiven inme, merdiven çıkma). Sınıflandırma, denetimli öğrenme yöntemlerinden biri olan Yapay Sinir Ağları yöntemi ile gerçekleştirilmiştir. %93 oranında doğru hareket tahmininde bulunmuştur.

Al Jeroudi ve ark. (2015), bir kullanıcının akıllı telefonundan toplanan verilere dayanarak insan hareketlerini sınıflandırmayı amaçlamışlardır. Bir Çevrimiçi Sıralı Aşırı Öğrenme Makinesi (OSELM) yöntemini, tek gizli katmanlı, ileriye beslemeli ağı (SLFN) eğitmek için uygulamışlardır. Elde edilen deneysel sonuçlar %82,05'in üzerinde olmuştur. Bu çalışmada, araştırmacıların farklı sınıflandırma algoritmalarını test etmişlerdir ve karşılaştırmalar için kamuya açık bir veri seti kullanmışlardır. Bu veri seti, otuz gönüllüden oluşan bir gruptan oluşmuştur. Her gönüllü altı hareketi bir Samsung Galaxy S2 akıllı telefonu beline yerleştirerek gerçekleştirmiştir. Bu akıllı telefonda 3-eksenli ivmeölçer ve jiroskop bulunmaktadır. Veri, insan vücudu hareketleri hakkında bilgi yakalayabilmek için gerekli olan 50 Hz ile örneklenmiştir. Bu altı hareket; düz zemin üzerinde yürümek, yukarı yürümek, aşağı yürümek, oturmak, ayakta durmak ve yatma şeklindedir.

Lara ve ark. (2013), çalışmalarında hareket tanıma alanında giyilebilir sensörlere dayanan çalışmalarında hareket tanıma sistemlerini tepki sürelerine ve öğrenmelerine göre organize eden iki seviyeli bir sınıflandırma getirmişlerdir. Yanıt süresi, öğrenme yaklaşımı, rahatsızlık verici olma, esneklik, tanıma doğruluğu ve diğer önemli tasarım konuları açısından yirmi sekiz sistem niteliksel olarak karşılaştırılmıştır. Hareket tanıma sisteminin önemli bileşenleri olan özellik çıkarma ve makine öğrenimi de dahil edilmiştir. Gelecek araştırmalar için bu alanı daha gerçekçi ve yaygın senaryolara genişleten çeşitli fikirler önermişlerdir. Öznitelik çıkarım yöntemlerini, zaman ve frekans düzlemlerindeki öznitelikleri ayrıntılı olarak incelemişlerdir.

İnsan aktivitelerinde sensörler gürültüden kolaylıkla etkilenebilmektedirler. Ponce ve ark. (2016), başarılı bir hareket sınıflandırma için gürültülü verilerle uğraşabilecek kadar kararlı ve sağlam makine öğrenme tekniklerinin kullanılması gerektiğini belirtmişlerdir. Çalışmalarında yapay bir hidrokarbon ağı (AHN) tekniğini

sunmuşlardır. AHN algoritması, kimyasal hidrokarbon bileşiklerinden esinlenen grafiksel bir model yapısına sahip denetlenen bir öğrenme algoritmasıdır. Yapay hidrokarbon ağlarının yeni yaklaşımı, HT açısından; bozuk veri sensörlerinin gürültü toleransı ve veri sensörleri üzerindeki farklı konularda sağlamlık için uygun olmaktadır. AHN sınıflandırıcısının HT için diğer makine öğrenme yöntemleriyle kıyaslamasını yapıp %97 oranla başarılı olduğunu belirtmişlerdir. Kullandıkları veri seti PAMAP2 (Reiss ve ark., 2012) adında 3.850.505 ham sinyal örneği içeren bir veri seti olmuştur. Bu veriler yirmi yedi yaş aralığındaki dokuz kişiye yerleştirilen üç adet sensörden alınan sinyallerden oluşmaktadır. Gönüllü kişiler on sekiz farklı aktiviteyi gerçekleştirmişlerdir. Bu aktiviteler uzanma, ayakta durma, yürüme, koşma, bisiklet sürme, televizyon izleme, araba sürme, ip atlama gibi hareketler olmuştur. Foerster ve Fahrenberg (2000); yürüyüş ve merdiven tırmanma gibi hareketlerin birbirinden ayırt edilmesi ve uyku esnasında vücudun rotasyonunu ayırt etmek için çalışmalarda bulunmuşlardır. Kayıtlar, on üç hareket ve duruş içeren standart bir protokole göre otuz bir denekten yapılmıştır ve hareketler üçer kere tekrarlanmıştır. Beş adet tek eksenli sensör ve üç yerleşim yeri (üç ekseninde sternum, sağ ve sol uyluk) seçilmiştir. Çok kanallı kayıtlar için Vitaport 2 kayıt aparatı kullanılmıştır. Aparat beldeki kemerde taşınarak kayıtlar elde edilmiştir. Beş farklı ivmeölçer sensör kullanılmıştır. İvme ve hız; ölçümde kişilerin farklı yerlerinde kullanılmıştır. Bu yerlerin bazıları, özellikle ivmeölçer cihazlarının kolaylıkla tespit edilebildiği (örneğin, el veya ayak bileği) konumlarda keyfi olarak seçilmiştir. Tanınması istenen hareketler; dik oturma, oturma-ileri dayanma, oturma-geriye yaslanmış, ayakta durma, sola dayanarak uzanma, sağa dayanarak uzanma, sırtüstü yatma, dizleri bükerek uzanma, normal hızda yürüyüş, hızlı yürüyüş, merdiven çıkma, merdiven inme, bisikletme sürme olarak belirlenmiştir. Sınıflandırma metodu olarak seçimlerini hiyerarşik sınıflandırmadan yana kullanmışlardır. Bu yöntemin, bireylerarası büyük değişkenlik ve duruş ve hareketin çok değişkenli modellenmesinden dolayı bu değerlendirmeler için uygun olduğuna kanaat getirmişlerdir. Elde ettikleri bulgulara göre kalibre edilmiş ivme ölçerlerin hareket ve duruşu değerlendirmede etkili olduğunu, iyi doğruluk sonuçları elde ettiklerini tespit etmişlerdir.

Tunçel ve ark. (2009), çalışmalarında gönüllü bir kişinin sağ bacağından alınan jiroskop sinyallerini kullanarak gerçekleştirdikleri 8 hareketi tespit etmeyi amaçlamışlardır. Farklı makine öğrenme yöntemleriyle hareketleri sınıflandırıp,

doğruluklarını karşılaştırmışlardır. Gönüllü kişinin diz bölgesinin üst ve alt kısmına iki adet jiroskop yerleştirip verileri elde etmişlerdir. Bu hareketler; ayakta durarak dizi hareketsiz tutma, öne doğru tekmeleme, dizi kırıp karın bölgesine yaklaştırma, öne doğru adım atmaya yönelme, geri adım atmaya yönelme, bacağı yan tarafa adım atmaya yönlendirme, çömelme, otururken bacağı yukarı doğru hareket ettirme. Çalışmalarında başta, çokça öznelik seçip değerlendirmeler yapmışlardır, daha sonra bu öznelikleri çeşitli sınıflandırma yöntemlerinde kullanmak üzere farklı değerlere indirgemişlerdir. Hareketler sınıflandırma aşamasında Bayes, Yapay Sinir Ağları (ANN), Destek Vektör Makinaları (SVM), En Yakın Komşuluk (KNN), En Küçük Kareler gibi makine öğrenmesi yöntemleri ile sınıflandırma işlemlerini gerçekleştirmişlerdir. En Küçük Kareler yönteminde 48 öznelikten 24 tanesi eğitim aşamasında kullanılmıştır ve %96'lık bir başarı elde etmiştir. En Yakın Komşuluk ile %95'lerde, Yapay Sinir Ağları ile %79'larda, Destek Vektör Makinesi ile sınıflandırma ile %94'lerde başarılar elde etmişlerdir. Jiroskop ile başarılı sonuçlar elde etmişlerdir.

Mantjarvi ve ark. (2001) çalışmalarında, insan HT için giyilebilir sensör olarak ivme sensörler kullanılmıştır. Özellik çıkarımında Temel Bileşen Analizi (PCA) ve Dalgacık Dönüşümü ile Bağımsız Bileşen Analizi (ICA) metotları uygulanmıştır. Makine öğrenmesi yöntemlerinden Çok Katmanlı Yapay Sinir Ağları kullanılarak sınıflandırmaya gidilmiştir. PCA, Dalgacık Dönüşümü ve ICA ile elde edilen sonuçlar karşılaştırılmıştır. Üç eksenli iki ivme ölçer sensör deneğin ön tarafına kalça hizasında sağ ve sol tarafına yerleştirilmiştir. 256 Hz'lik veri bir bilgisayara kaydedilmiştir. Altı denek ile bir ofis ortamında hareketler gerçekleştirilmiştir. Senaryo; yürüme, merdiven tırmanma ve inme ve kapı açmaktan ibaret olarak gerçekleştirilmiştir. Elde edilen sonuçlar %83 ile %90 arasında değişmiştir.

Ham veriyi faydalı bağlamsal bilgiye dönüştürmek için makine öğrenme teknikleri, yani konunun durumu hakkında bilgi vermek için yararlı bilgiler gerekli olmaktadır. HT yeteneğini en üst düzeye çıkarmak için, bu teknikler, yüksek ayırt etme becerisine sahip veri özneliklerini üretebilmeli ve seçebilmelidir. Özellik seçimi, sınıflandırma modelinin oluşturulmasında kullanılacak ilgili özelliklerin bir alt kümesini seçme işlemidir. Literatür çalışmalarına bakıldığında HT aşamasındaki önemi artık fark edilen öznelik çıkarımına ilişkin çeşitli yaklaşımlar yer almaktadır. Bunlardan Relief-F; alaka düzeylerine göre ağırlıklandırarak özellikleri sıralayan sık kullanılan bir filtre yöntemidir. Özellikle; alakalılık ve veri örneklerinin ne kadar iyi ayrıldığına bağlıdır.

Korelasyona Dayalı Özellik Seçimi (CFS); korelasyon tabanlı değerlendirme fonksiyonu ile özelliklerin alt gruplarını sıralayan bir filtre algoritmasıdır. Bir özellik, hedef konuyla alakalıysa, ancak diğer ilgili özelliklerden herhangi biriyle gereksiz olması halinde, iyi bir özellik olarak kabul edilmektedir. Ölçüm iyiliği, özellikler arasındaki bir korelasyon ile ifade edilmektedir. CFS, en yüksek önemi alan özelliklerin alt kümesini seçmektedir. CFS, özelliklerin korelasyonunu sınıflayıp, öngörebilme yetenekleri ile birlikte incelerken korelasyon tabanlı buluşsal yöntemle özelliklerin ilgisini değerlendirmektedir. Bu nedenle, CFS, sınıfla yüksek orantılı olan ve birbirleriyle ilişkisiz olan özellikleri seçmektedir. Hızlı Korelasyona Dayalı Filtre (FCBF) yöntemi, özellikler ve sınıflar arasındaki baskın korelasyonu inceleyerek ve fazlalık eşlerden baskın özellikleri seçerek özellik liyakatini değerlendirmektedir. PCA, veri boyutsallığını azaltmak için kullanılan en basit yöntemdir. Bu azaltılmış boyutsal veriler doğrudan sınıflandırma için özellik olarak kullanılabilir. Bir dizi özellik verildiğinde, PCA analizi, önceki PCA bileşene dikey olan alt uzayda en yüksek varyansa sahip özelliklerin doğrusal kombinasyonları olarak yeni veri değişkenleri (PCA bileşenleri) üretmektedir. PCA yönteminin çeşitli uzantıları çekirdek PCA, seyrek PCA ve çok çizgili PCA gibi bilinmektedir. Bunların dışında öznitelik kümeleme, heuristic, Simba, SFFS (Pudil algoritması), MRMR (Minimum Redundancy and Maximum Relevance) gibi öznitelik çıkarım yöntemleri de literatürde HT ile ilgili çalışmalara kazandırılmıştır.

Capela ve ark. (2015) çalışmalarında HT için, ivmeölçer ve jiroskop sensörlerine sahip akıllı telefon sinyallerini kullanarak üç filtre tabanlı bir öznitelik çıkarım metodu kullanıp sınıflandırmayı amaçlamışlardır. Uygulamalarında Blackberry Z10 cep telefonu kullanılmıştır. Çünkü normal cep telefonlarının çoğunda ivmeölçerler bulunmaktadır, fakat BlackBerry telefonda yerçekimine göre ivme değerleri de elde edilebilmektedir. Veri setleri yaşlı hastalardan elde edilmiştir ve toplam kırk dört katılımcı için toplam on sekiz farklı veri toplanmıştır. Bu katılımcıların on beşi sağlıklı, on yedisi yaşlı ve on ikisi yaşlı ve hasta olan kişilerden alınan veriler olmuştur. Katılımcıların günlük aktiviteleri gerçekleştirmeleri beklenmiştir. Elde edilen yetmiş altı sinyale öznitelik çıkarımı için üç filtre tabanlı yöntem uygulanmıştır. Bunlar; Relief-F, CFS ve FCFS'dir. Daha sonra özellik alt kümeleri üç genel sınıflandırıcı (Naive Bayes, Destek Vektör Makinesi, J48 Karar Ağacı) kullanılarak değerlendirilmiştir. Capela ve ark. (2015)'nin asıl amacı hareket tanıma için sınıflandırıcıdan bağımsız olarak bele

yerleştirilen cep telefonundan en iyi öznitelikleri elde etmektir. Hareketleri sınıflandırırken hareket sayısı arttıkça doğruluk yüzdesinin düşüşü dikkati çekmiştir. Bu yüzden geniş bir aralığa sahip sonuçlar elde etmişlerdir.

Howcroft ve ark. (2017) yaptıkları çalışmanın amacı, giyilebilir ivmeölçerden ve basıncı algılayan tabanlıklardan elde edilen yürüyüş verilerinden türetilmiş geniş özellik kümelerinden, daha iyi sınıflandırma başarısı için daha küçük öznitelik kümelerini tanımlamak ve değerlendirmek olmuştur. Yüz yaşlı erişkin; kafa, pelvis, sol ve sağ bacaklarına basınca duyarlı tabanlık ve üç eksenli ivmeölçer giyip 7,62 km yürüyüş yapmıştır. Veri kümesi bahsedilen bölgelerden alınan sinyallerden elde edilmiştir. Özellik seçimi için CFS, FCBF ve Relief-F algoritmaları kullanılarak gerçekleştirilmiştir. Faller sınıflaması tekrarlanan rasgele örnekleme ile, Çok Katmanlı Yapay Sinir Ağı, Naive Bayesian ve Destek Vektör Makinesi sınıflandırıcıları kullanılarak gerçekleştirilmiştir. Elde ettikleri sonuçlara göre en iyi performans gösteren model, %78 doğruluk, %26 duyarlılık, %95 özgüllük, 0,36 F1 skoru ve bir posterior pelvis ivmeölçer giriş özelliği (sol ivme standart sapması) olan bir destek vektör makinesidir. İkinci en iyi modelleri daha iyi hassasiyet (%44) elde etmiştir ve %74 doğruluk, %83 özgüllük, 0,44 F1 skoru ile bir destek vektör makinesi kullanılmıştır. Bu model on girdiye sahip olmuştur: maksimum, ortalama, standart sapma, posterior ivme, maksimum, ortalama, standart sapma ön ivmesi, ortalama, üstün hızlanma ve üç impuls özellikleri olmuştur. En iyi çok sensörlü model duyarlılığını (%56) posterior pelvis ve her iki ivme ivmeölçeri ve Naive Bayesian sınıflandırıcısı kullanılarak sağlamışlardır. En iyi tek sensörlü model hassasiyetini (%41), posterior pelvis ivmeölçeri ve Naive Bayesian sınıflandırıcısını kullanarak elde etmişlerdir. CFS ve FCBF yöntemlerinden sınıflandırma için Relief-F'ye göre daha iyi öznitelik elde etme başarısı sağlamışlardır.

..... Damasevicius ve ark. (2016) çalışmalarında, yüksek boyutlu özniteliklerden, düşük boyutlu özniteliklere geçiş yapıp, verilerin olasılık yoğunluk fonksiyonları arasındaki Jaccard mesafesini kullanıp sınıflandırma yapılarak günlük insan faaliyetlerinin çevrimdışı tanınması için bir yöntem önermişlerdir. Öznitelik seçim aşamasında PCA, Relief-F, Rank Features metotlarını kullanmışlardır. Sınıflandırmayı tahmin etmede bir kriter olarak, her sınıfı temsil eden veri noktalarının iki olasılık yoğunluğu tahminleri arasındaki Jaccard mesafe metriğini kullanmışlardır. Kullandıkları veriseti (USC-HAD Dataset) cep telefonundan elde edilen sinyaller ile yedi kadın, yedi erkek on dört katılımcının on iki aktiviteyi beş tekrarla yapmalarıyla elde edilmiştir. Bu



hareketler; ileri yürüme, sola yürüme, sağa yürüme, merdiven çıkma, merdiven inme, ileri koşma, zıplama, oturma, ayakta durma, uyuma, asansörle yukarı çıkma, asansörle aşağı inme olmuştur. Elde edilen sonuçlara göre ortalama %94'lük bir doğruluk elde edilmiştir.

Elvira ve ark. (2014) çalışmalarında, atalet ve manyetik sensörleri kullanarak insan HT için yeni bir öznitelik çıkarım yöntemiyle ilgilenmişlerdir. Önerilen yöntem, kuaterniyon gösterimini kullanarak kişinin yeryüzüne göre yönünü tahmin etmektedir. Çalışmalarında kullandıkları sensör MARG; manyetik, açısal hız ve yerçekimi sensörü, 3 eksenli manyometreyi de entegre eden genişletilmiş atalet ölçü birimidir. Çalışmalarında MARG sensörü tarafından alınan sinyallerden öznitelik çıkarımını amaçlamışlardır. Önerilen öznitelik çıkarım aşamasında MARG sensörleri tarafından sağlanan manyetik, açısal hız ve ivmeölçer sinyalleri işlenmiştir. Bu sensörden kişinin yönü ve kişinin ivmesi elde edilmiştir. Elvira ve ark. (2014)'na göre jiroskoplar tarafından sağlanan açısal hız ölçümlerinin sınıflandırma algoritmaları için değerli sinyaller olmadığı yönünde olmuştur. On sekiz kişiden yürüme, koşma, ayakta durma, uzanma hareketlerinden elde edilen değerler kullanarak sınıflandırma gerçekleştirilmiştir. Rastgele oniki kişiden alınan veri; eğitim için, kalan diğer altı kişiden alınan veriler ise test için kullanılmıştır. Veriler Kuaterniyon Hızlanma yöntemi (AQ), ve İvmesel Açı Hızlanma yöntemi (AAR) ile işlenmişlerdir. AQ yöntemi için farklı değişken değerleri ile öznitelikler elde edilmiştir. Önerilen öznitelik çıkarma tekniğini, Gizli Markov Modellerine (HMM) dayalı en gelişmiş bir Hiyerarşik Dinamik Modele (HDM) uygulayarak performansını değerlendirmişlerdir. Her bir HMM, hareket başına beş durum kullanarak, diğer bir deyişle, tanımlanabilir yirmi beş duruma sahip küresel bir modele ve üç bileşenli bir Gauss Karışım Modeli (GMM) olasılık dağılımına dayanılarak modellenmiştir. Test aşamasında ise Forward-Backward algoritması kullanılmıştır. Elde ettikleri sonuçlara göre öznitelikler elde edildikten sonra yapılan sınıflandırmanın daha yüksek doğruluklu olduğunu tespit etmişlerdir. %86-%89 arasında başarılı sınıflandırma gerçekleştirilmiştir.

Atallah ve ark. (2011), ivme sensörleri kullanıp Relief-F, Simba ve MRMR öznitelik çıkarım yöntemlerini kullanarak çeşitli hareketleri sınıflandırmaya çalışmışlardır. Bu aktiviteler; yatmak, yemek hazırlamak, yemek yiyip içmek, sosyalleşmek, okumak, giyinmek, yürüyüş, koşu bandında yürüyüş, vakumlama, masaları silme, bisiklet sürmek, oturmak ve kalkmak, yatmak ve kalkmak. Toplamda

yüz yirmi dört tane öznelik elde etmişlerdir ve sınıflandırmayı KNN ve Bayes algoritmalarını kullanarak gerçekleştirmişlerdir. Ortalama %90 doğruluk başarısı elde etmişlerdir.

Bayat ve ark. (2014), üç eksenli ivmeölçerleri (cep telefonunu) kullanıp koşma, yürüme, aerobik dans etme, merdiven çıkma, merdiven inme hareketlerini tanımayı amaçlamıştır. Özellik kümeleme gerçekleştirerek sınıflandırma için gerekli öznelikleri elde etmişlerdir. Sınıflandırmada kullandıkları algoritmalar; Çok Katmanlı ANN, SVM, Random Forest' tır. Ortalama %81-%91 arası doğruluk elde etmişlerdir.

Parkka ve ark. (2006) çalışmalarında, GPS, ses, EKG, ivmeölçer, pusula, nem, ışık, sıcaklık, nabız, cilt direnci gibi faktörlerden yararlanarak HT'yı amaçlamışlardır. Tanımak istedikleri hareketler; yere uzanma, kürek çekme, oturma, ayakta durma, koşma, yürümedir. Heuristik öznelik çıkarım yöntemlerini uygulamışlardır. Karar ağaçları ile sınıflandırma algoritmalarını kullanarak %86 doğruluk başarısı elde etmişlerdir.

Maurer ve ark. (2006), yürümek, ayakta durmak, koşmak, merdiven çıkmak ve merdiven inmek aktivitelerini tanımayı amaçlamışlardır. Veri elde etmek için çoklu sensörlerden faydalanmışlardır. CFS öznelik elde etmek için ve sınıflandırmayı gerçekleştirmek için Karar Ağaçları, KNN, Naive Bayes ve Bayes Net algoritmalarını kullanmışlardır. %80-%92 doğruluk başarısına ulaşmışlardır.

Kurban (2014), tez çalışmasında düşme tespiti ve HT işlemlerini; herhangi bir öznelik çıkarım yöntemi kullanmadan gerçekleştirebilecek bir sistem elde etmiştir. Yürümek, oturmak, kalkmak, zıplamak, koşmak, durmak ve düşmek şeklindeki hareketlerin tespiti için bir ivme sensörü olan eZ430-Chronos mikrodenetleyici tabanlı bir kit kullanılmıştır. Ölçüm alabilmek için kit; vucutta bel, diz ve el bileğine yerleştirilerek veriler elde edilmiştir. Yirmi gönüllünün belirlenen hareketleri yapması istenmiştir. Fakat kullanılan kitten dolayı veri kayıpları yaşanmıştır. Bu durumu en aza indirmek için Lineer İnterpolasyon işlemi uygulanmıştır. Normalizasyon için Max yöntemi kullanılmıştır. Çok Katmanlı Algılayıcı Sınıflandırma Yöntemi, SVM sınıflandırmasını, ANN yapısında Radyal Tabanlı Fonksiyon ve Naive bayes sınıflayıcıları kullanılarak sınıflandırma başarıları tespit edilmiştir.







### 3. MATERYAL VE METOT


#### 3.1. Materyal

Bu tezde kullanılan veri kümesi; UCI kütüphanesindeki MHealth (Mobile Health) veri kümesidir (Banos ve ark., 2015). Toplanan veri seti; on iki fiziksel aktivite gerçekleştirirken vücut hareketi ve yaşamsal belirti kayıtlarını içeren çeşitli gönüllülerin kayıtlarını içermektedir. Kayıtlar için Shimmer2 (BUR10) giyilebilir üç adet sensör kullanılmıştır. Sensörler, sırasıyla kişilerin göğüs, sağ el bilekleri ve sol ayak bileklerine yerleştirilmiş ve elastik kayışlar kullanılarak takılmıştır. Birden fazla sensör kullanılması, vücut bölümlerinin çeşitli hareketleri; yani ivme, dönüş hızı ve manyetik alan yönelimini ölçmeyi sağlamaktadır. Böylece vücut dinamikleri daha iyi yakalanabilmektedir. Göğüste konumlandırılan sensör, iki derivasyonlu EEG ölçümlerini sağlamaktadır. Sinyaller 50 Hz'lik bir örnekleme hızında kaydedilmektedir ve insan hareketlerini yakalamak için yeterli sayılmaktadır. Her oturum bir video kamera kullanılarak kaydedilmiştir. Bu veri setindeki aktiviteler, günlük yaşamın genel aktivitelerine göre seçilmiştir. Bu veri setinin oluşturulması için on gönüllünün kayıtları alınmıştır. Her gönüllü on iki fiziksel hareketi gerçekleştirmiştir. Gerçekleştirilen aktiviteler Tablo 3.1'de gösterilmiştir. Ayrıca göğüs ve sağ el bilekleri ve sol ayak bileklerine takılan cayo, ivme ve manyometre sensörlerinden alınan sinyallere ait örnekler Şekil 3.1'de verilmiştir. Sinyal örnekleri sırayla Tablo 3.1'deki aktivitelere aittir.

**Tablo 3.1.** Veri kümesinde yer alan aktivite seti

Etiket	Aktivite
L1	Hareketsiz durma (1 dk.)
L2	Oturma ve rahatlama (1 dk.)
L3	Uzanma (1 dk.)
L4	Yürüme (1 dk.)
L5	Merdiven çıkma (1 dk.)
L6	Öne eğilme (20 kez)
L7	Kolları yukarı kaldırma (20 kez)
L8	Dizleri bükme (Çömelme) (20 kez)
L9	Bisiklet sürme (1 dk.)
L10	Tempolu yürüyüş yapma (1 dk.)
L11	Koşma (1 dk.)
L12	Öne ve arkaya zıplama (20 kez)





**Şekil 3.1.** Çalışmada kullanılan örnek sinyaller

(a) L1 hareketine ait sinyal, (b) L2 hareketine ait sinyal, (c) L3 hareketine ait sinyal, (d) L4 hareketine ait sinyal, (e) L5 hareketine ait sinyal, (f) L6 hareketine ait sinyal, (g) L7 hareketine ait sinyal, (h) L8 hareketine ait sinyal, (i) L9 hareketine ait sinyal, (i) L10 hareketine ait sinyal, (j) L11 hareketine ait sinyal, (k) L12 hareketine ait sinyal

Sinyaller farklı sensörlerden elde edilmiştir. Yirmi üç farklı kanaldan; göğüs, el ve ayak bileklerinden; ivme, cayro ve manyometre sensörleri kullanılarak veriler toplanmıştır. Bu kanallar Tablo 3.2’de verilmiştir.

**Tablo 3.2.** Sinyallerin elde edildiği sensörler

Kanal	Açıklama
Kanal 1	Göğüs bölgesine takılan ivme (acceleration) sensörünün X eksen
Kanal 2	Göğüs bölgesine takılan ivme (acceleration) sensörünün Y eksen
Kanal 3	Göğüs bölgesine takılan ivme (acceleration) sensörünün Z eksen
Kanal 4	EEG sinyali
Kanal 5	EEG sinyali
Kanal 6	Sol ayak bileğine takılan ivme (acceleration) sensörünün X eksen
Kanal 7	Sol ayak bileğine takılan ivme (acceleration) sensörünün Y eksen
Kanal 8	Sol ayak bileğine takılan ivme (acceleration) sensörünün Z eksen
Kanal 9	Sol ayak bileğine takılan cayro (gyro) sensörünün X eksen
Kanal 10	Sol ayak bileğine takılan cayro (gyro) sensörünün Y eksen
Kanal 11	Sol ayak bileğine takılan cayro (gyro) sensörünün Z eksen
Kanal 12	Sol ayak bileğine takılan manyometre (magnetometer) sensörünün X eksen
Kanal 13	Sol ayak bileğine takılan manyometre (magnetometer) sensörünün Y eksen
Kanal 14	Sol ayak bileğine takılan manyometre (magnetometer) sensörünün Z eksen
Kanal 15	Sağ el bileğine takılan ivme (acceleration) sensörünün X eksen
Kanal 16	Sağ el bileğine takılan ivme (acceleration) sensörünün Y eksen
Kanal 17	Sağ el bileğine takılan ivme (acceleration) sensörünün Z eksen
Kanal 18	Sağ el bileğine takılan cayro (gyro) sensörünün X eksen
Kanal 19	Sağ el bileğine takılan cayro (gyro) sensörünün Y eksen
Kanal 20	Sağ el bileğine takılan cayro (gyro) sensörünün Z eksen
Kanal 21	Sağ el bileğine takılan manyometre (magnetometer) sensörünün X eksen
Kanal 22	Sağ el bileğine takılan manyometre (magnetometer) sensörünün Y eksen
Kanal 23	Sağ el bileğine takılan manyometre (magnetometer) sensörünün Z eksen

## 3.2. Metot

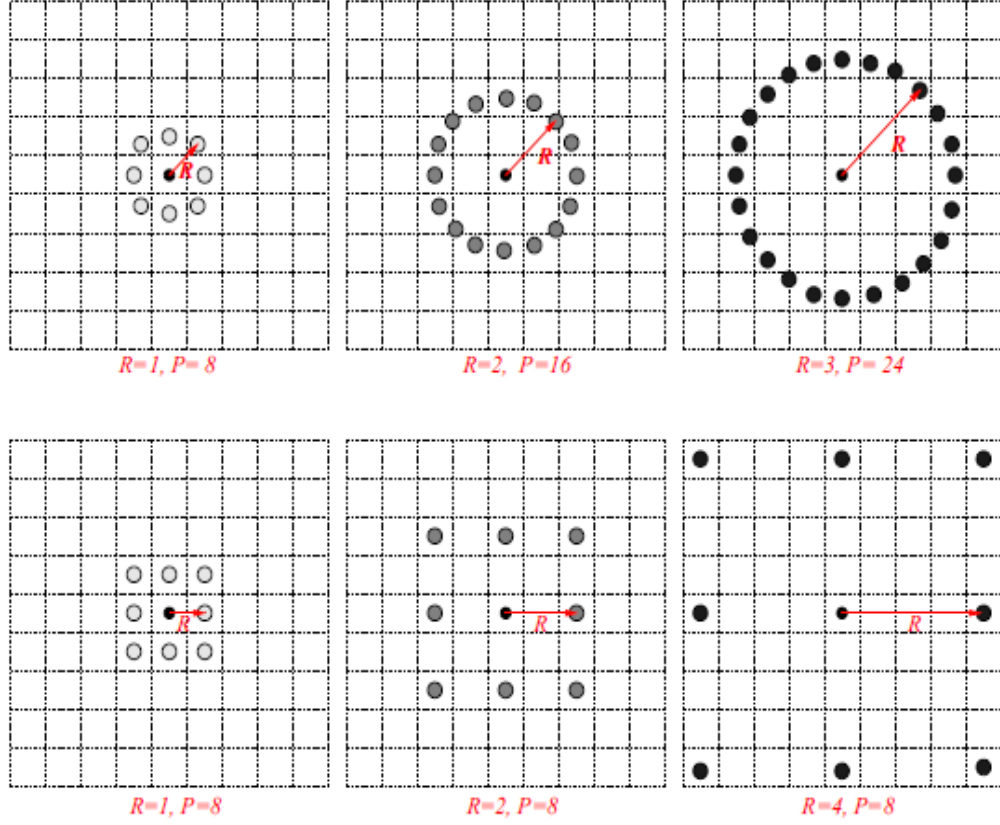
### 3.2.1. Yerel ikili örüntüler (YİÖ)

Yerel İkili Örüntü (YİÖ) operatörü yerel komşuluğa dayanan bir istatistiksel öznitelik çıkarım metodudur. Bu metodu ilk defa Ojala ve arkadaşları ortaya atmıştır (Ojala ve ark., 1996). YİÖ operatörü, başlarda yerel görüntü kontrastı için tamamlayıcı bir ölçüt olarak tanıtıldı.

YİÖ operatörü ile öznitelik vektörü daha kolay bir şekilde hesaplanabilmektedir. Bu yöntem ışık değişikliklerinden pek etkilenmediği için görüntü tabanlı sistemlerde öznitelik elde etme metodu olarak sıkça rağbet görmektedir. YİÖ operatörü; endüstride kontrol sistemlerinde, kumaş üretiminde yüzey hatalarını tespit etmek için doku sınıflandırmada, yüz tespiti, yaş tahmini, yüz mimik ve jestlerinden duygu tahmini, hareket eden nesnelerin takibi vb. uygulamalarda çalışılmış ve yüksek doğruluklu sonuçlar elde edilmiştir (Ojala ve ark., 2002; Maaenpaa ve Pietikaainen, 2004; Feng ve ark., 2005; Nabiyeve ve Kurt, 2007; Gunay ve Nabiyeve, 2008; Nabiyeve ve Kurt, 2011).

YİÖ ayrıştırmada çok iyi ve başarılı sonuçlar elde edebilen bir örüntü analiz yöntemidir (Ojala ve ark., 2000). YİÖ yönteminde; iki boyutlu bir resimdeki her piksel, kendi etrafındaki sekiz piksel ile karşılaştırılarak merkez piksel için ikili bir dizge oluşturulmaktadır. Bu ikili dizgenin onluk karşılığı merkez pikselin yeni değeri olarak kabul edilmektedir. YİÖ'nün asıl versiyonunda, YİÖ operatörü, pikselin sadece sekiz komşusunu göz önünde bulundurmaktadır. Ama herhangi piksel sayılı bütün dairesel komşulukları kapsayacak şekilde genişletilebilmektedir (Ojala ve ark., 1996; Ojala ve ark., 2002). Komşuların durumuna göre farklı farklı YİÖ operatörleri tanımlanabilmektedir (Şekil 3.2). YİÖ operatörün iki önemli parametresi bulunmaktadır. İlk parametre; komşuluk adedini ifade eden  $P$ 'dir. Uygulamalarda  $P$  genellikle sekiz olarak alınmaktadır. Ancak  $P$  farklı değerler de alabilir. YİÖ görüntü oluşturulurken  $P$  değeri yüksek seçildiği takdirde hem öznitelik histogramı büyümekte hem de işlem maliyeti artmaktadır.  $P$  değeri çok küçük seçildiğinde ise bilgi kayıplarına sebep olabilmektedir. YİÖ'nün bir diğer parametresi ise ölçeğini belirten  $R$  değeridir.  $R$  değeri; komşu piksel değerlerinin merkez piksel değerine ne kadar uzak olduğunun ölçüsüdür.  $R$ 'nin farklı değerleriyle farklı ölçeğe sahip görüntülerin analizi yapılabilmektedir. Dairesel komşuluklarda da bu notasyonu gerçekleştirilmektedir, farklı  $P$  ve  $R$  değerleri ile farklı ölçeklerdeki doku ve görüntülerin analizi

gerçekleştirilebilmektedir.  $Y\ddot{O}_{P,R}$  gösterimiyle ifade edilmektedir. Şekil 3.2’de farklı  $Y\ddot{O}$  operatörleri gösterilmiştir.



Şekil 3.2. Farklı  $Y\ddot{O}$  operatörleri için dairesel simetrik komşu kümeleri

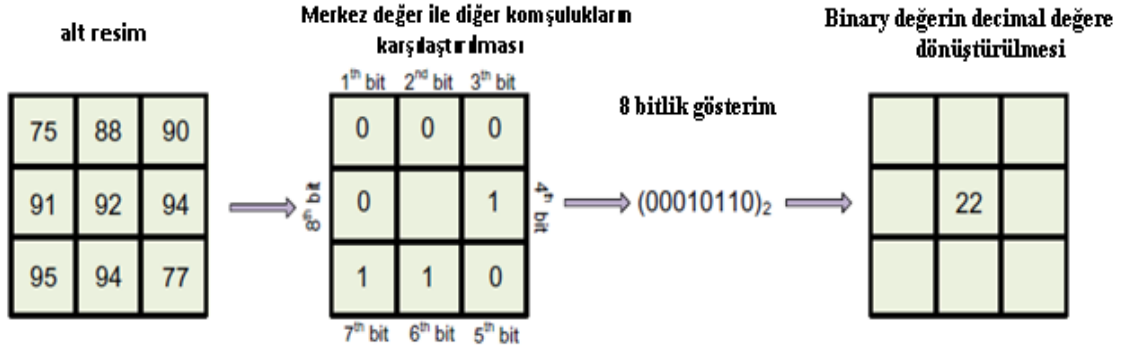
$Y\ddot{O}$  operatörü, görüntüdeki her piksel değerini, merkez piksel olarak görüp ve bu merkez piksel değerini eşik değeri olarak kabul edip çevresindeki komşu piksel değerlerini merkez değer ile kıyaslamaktadır. Eğer komşu piksel değeri merkez pikselin değerinden büyük veya eşitse bu piksel 1 değerini almaktadır, diğer durumda ise 0 değerini almakta ve en sonunda bir ikili değer oluşmaktadır. Oluşan bu ikili kod ardından, onluk değere dönüştürülmektedir. Onluk değer; verilen pikselin etrafındaki yerel yapısal bilgiyi vermektedir (Şekil 3.3).

$Y\ddot{O}$  operatörünün bir piksel için matematiksel formülü Denklem (3.1)’de gösterildiği gibidir.

$P_c$ ; merkez pikselin değeri,  $P_i$ ;  $i$ 'inci komşuluğun değeri olmak üzere,

$$t = P_i - P_c \text{ ve } F(t) = \begin{cases} 1 & \text{if } t \geq 0 \\ 0 & \text{if } t < 0 \end{cases} \text{ iken; } Y\ddot{O}(x) = \sum_{i=0}^P F(t)2^i \text{ dir.} \quad (3.1)$$





**Şekil 3.3.** YİÖ kodunun hesaplanması

Şekil 3.3'deki alt resimde;  $P = \{P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7\}$  olan komşu değerleri sırasıyla 75, 88, 90, 94, 77, 94, 95, 91 ve  $P_c$  merkez değeri 92'dir. Denklem (3.1)'den,  $F(t) = \{t_0, t_1, t_2, t_3, t_4, t_5, t_6, t_7, t_8\}$  hesaplanmıştır.  $P_c = \{S(75 < 92), S(88 < 92), S(90 < 92), S(94 \geq 92), S(77 < 92), S(94 \geq 92), S(95 \geq 92), S(91 < 92)\}$  ve  $F(t) = \{0, 0, 0, 1, 0, 1, 1, 0\}$  elde edilmiştir. Bu sekiz bitlik ikili dizge onluk değere dönüştürüldüğünde 22 onluk değeri elde edilir. Bu değer merkez değer in yeni değeri, yani YİÖ kodu olmuş olur.

Yapılan bazı çalışmalara göre görüntü yüzeylerinin çoğunun uniform örüntüler olduğu görülmüştür. Uniform örüntü; bir YİÖ kodunda 0'dan 1'e ya da 1'den 0'a geçiş sayısının 2veya 2'den az olması durumudur. '00011000' ve '00111100' örüntülerinde 2 geçiş olduğundan bunlar uniform örüntülere örnektir. Bir YİÖ'de  $(P-1)(P+2)$  uniform örüntü bulunmaktadır.


### 3.2.2. Bir boyutlu yerel ikili örüntüler (1B-YİÖ)

Bu çalışmada, sensör sinyalleriyle ilgili önemli bilgileri yakalayabilmek için özellik çıkarma yöntemi olarak 1B-YİÖ kullanılmıştır. 1B-YİÖ metodu, öznelik çıkarımında sıkça kullanılan bir yöntem olan YİÖ'den geliştirilmiştir, yapısal ve işleyiş yönünden YİÖ ile benzerlik göstermektedir. YİÖ operatörü nonparametrikdir. Ancak 1B-YİÖ metodu, zaman serisi şeklindeki bir boyutlu dizilimi olan sinyaller için veri işlemede farklı uygulama alanlarında kullanılmak üzere geliştirilmiştir (Kaya ve ark., 2014; Kaya ve ark., 2015; Ertuğrul ve ark., 2015).

Görüntüler için kullanılan YİÖ'ler, 2B-YİÖ olarak adlandırılan iki boyutlu piksel komşusunu kullanmaktadırlar.

Sinyaldeki merkez değer olarak belirlenen her bir değer, belirlenen komşu değerleri ile ikili karşılaştırmalar yapılarak ikili kodlar elde edilmektedir. Bu işlem, tüm sinyal boyunca tekrarlanmaktadır. Bu ikili kodların onluk karşılıklarından elde edilen sinyal ise yeni bir sinyal olan 1B-YİÖ sinyalidir (Kaya ve ark., 2014).

1B-YİÖ ile öznitelik çıkarma yöntemi adım adım örnek sinyalin bir bölümü üzerinde açıklanmıştır. Şekil 3.4'te 1B-YİÖ metodunu uygulamak için sinyalden alınan merkez nokta ve komşulukları gösterilmektedir.



Şekil 3.4. Ayakta durma pozisyonu olan L1 hareketinden elde edilmiş olan ECG sinyallerinden 1B-YİÖ kodu hesaplama

1B-YİÖ metodunun matematiksel formülasyonu YİÖ metodu ile aynıdır. Denklem (3.1) kullanılarak 1B-YİÖ kodunun hesaplanması için gereken aşamalar aşağıdaki gibidir:

Birinci aşamada; verilen bu sinyalde 1B-YİÖ operatörü merkez değer ile komşu değerleri arasında sıralı bir ikili karşılaştırma kümesi olarak tanımlanmıştır. Sinyal üzerindeki her bir değer için öncesinden ve sonrasında toplamda P adet komşu değer seçilmiştir. Öncesinden  $P/2$  ve sonrasında  $P/2$  komşu alınmıştır. Bu çalışmada  $P=8$  için 8 tane komşu nokta belirlenmiştir. Her bir nokta merkez değer ( $P_c$ ) olarak alındığında  $P_c$ 'den önce ( $P_0, P_1, P_2, P_3$ ) ve sonra ( $P_4, P_5, P_6, P_7$ ) yer almaktadır. Şekil 3.4'teki sinyal üzerindeki bir bölüm aşağıdaki gibi gösterilip sinyal üzerinde  $P_c$  ve  $P_i$  değerleri gösterilmiştir.

P0	P1	P2	P3	Pc	P4	P5	P6	P7
9.75	9.5	12.62	11.10	12.11	13.15	11.20	10.8	13.5

Şekil 3.5. Sinyal üzerindeki örnek değerler

İkinci aşamada; Şekil 3.5’de görüldüğü gibi bütün komşuluk değerleri  $P = \{P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7\}$   $P_c$  merkez değeri ile karşılaştırılmaktadır.

Üçüncü aşamada; Denklem (3.1)’ de görüldüğü üzere 8 komşu değer  $P_c$  değeri ile karşılaştırılarak bir ikili değer elde edilmiştir ( $F(P_i - P_c)$ ). Komşu  $P_i$  değeri merkezi değerden büyük veya ona eşitse, bu  $P_i$  değeri 1 olmaktadır, aksi takdirde 0 değerini almaktadır (Şekil 3.6).

P0	P1	P2	P3	Pc	P4	P5	P6	P7
0	0	1	0	12.11	1	0	0	1

Şekil 3.6.  $P_c$  ve  $P_i$  komşu değerlerinin karşılaştırılması (Denklem (3.1)’ ün uygulanması)

Dördüncü aşamada; elde edilen bu ikili dizge ondalık değere dönüştürülmektedir (Şekil 3.7). Böylece komşuluk için ikili bir YİÖ kodu meydana gelmektedir. Bu ikili kodun ondalık değeri verilen  $P_c$  noktasının çevresindeki yerel yapı bilgisini temsil etmektedir.

P0	P1	P2	P3	Pc	P4	P5	P6	P7
0	0	1	0	41	1	0	0	1

Şekil 3.7. İkili dizgeden elde edilen 1B-YİÖ kodu

Şekil 3.8’den görüldüğü gibi merkez değerinin ilk değeri 12,11 iken 1B-YİÖ dönüşümünden sonra yeni değeri 41 olarak elde edilmiştir.

P0	P1	P2	P3	Pc	P4	P5	P6	P7
9.75	9.5	12.62	11.10	12.11	13.15	11.20	10.8	13.5
P0	P1	P2	P3	Pc	P4	P5	P6	P7
0	0	1	0	41	1	0	0	1

$$00101001=41$$

Şekil 3.8. Sinyalden elde edilmiş olan 1B-YİÖ kodu

Beşinci aşamada; yukarıdaki adımlar tek tek sinyal üzerindeki tüm değerler için gerçekleştirilmektedir. Uygulanan bu yöntem ile 0-255 aralığında değerlere sahip 1B-YİÖ sinyali elde edilmiştir. Diğer bir deyişle 1B-YİÖ sinyali 0-255 aralığındaki değerlerden oluşmaktadır. Elde edilen her bir değerın frekansı; bir örüntünün ifadesidir. 1B-YİÖ operatörü, sinyalin alternatif bir gösterimi olarak kullanılabilen 1B-YİÖ kodlarının histogramını oluşturmak amacıyla kullanılmaktadır.

### 3.2.3. Öznitelik çıkarımı

Bu çalışmada farklı kanallardan elde edilmiş 23 kanala ait sensör verileri kullanılmıştır. Her sensöre ait sinyal verilerine 1B-YİÖ yöntemi uygulandıktan sonra yine hareketleri sınıflandırmada ayırt ediciliği yüksek olacağı düşünülen istatistiksel bazı öznitelikler çıkartılmıştır. Bu öznitelikler hareket sınıflandırmanın kalitesini arttırıp, daha yüksek doğruluklu sonuçlar elde edilmesini sağlamaktadır. Bu öznitelikler aşağıda ayrıntılı olarak açıklanmıştır.

#### 3.2.3.1. Medyan (Ortanca)

Var olan bir veri dizisinin dizilimine göre sayısal büyüklükleri baz alınarak bir sıralama gerçekleştirildiğinde ortadaki sayıya ‘medyan’ adı verilmektedir. Örnek olarak 3, 2, 2, 7, 2, 9, 5, 5, 5, 8, 9 dizisinde değerler büyüklüklerine göre dizildiklerinde 2, 2, 2, 3, 5, 5, 5, 7, 8, 9, 9 dizisi meydana gelir. Bu 11 elemanlı dizide ortadaki değer, yani 6. değer olan 5 sayısı medyandır. Tek sayı elemanlı bir dizinin medyan değerinin sırası Denklem (3.2)’de görüldüğü şekilde hesaplanmaktadır.

$$\text{Medyanın Sırası} = (\text{Eleman Sayısı} + 1) / 2 \quad (3.2)$$

Çift sayı elemanlı bir dizinin medyan değerinin sırası Denklem (3.3)’de görüldüğü şekilde hesaplanmaktadır.

$$1. \text{ Medyanın Sırası} = \text{Eleman Sayısı} / 2$$

$$2. \text{ Medyanın Sırası} = (\text{Eleman Sayısı} / 2) + \quad (3.3)$$

#### 3.2.3.2. Standart sapma

Bir veri dizisindeki verilerin her birinin aritmetik ortalama etrafındaki dağılımının ölçüsüne ‘Standart sapma’ denir. Standart sapma hesabı; verilerin aritmetik

ortalamaya yakınlık ölçüsünü tespit etmektedir. Standart sapma değerinin küçük olduğu veri dizilerinde veriler ortalama değerine yakın olarak yayılmışlardır. Standart sapmanın büyük olduğu veri dizilerinde ise veriler ortalama değerinden uzaklaşmışlardır. Bütün verileri aynı olan bir veri dizisinin standart sapması sıfırdır. Formülasyon Denklem (3.4)' da gösterildiği gibidir.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (3.4)$$

$\sigma$ ; standart sapma,  $N$ ; eleman sayısı,  $\bar{x}$ ; sayıların aritmetik ortalamasıdır.

### 3.2.3.3. Varyasyon

Varyasyon; bir dağılıma dahil verilerin her birinin aritmetik ortalamaya ne kadar uzakta olduğunun başka bir deyişle dağılımının ölçüsüdür. Aritmetik ortalama; bir dağılımdaki orta noktayı ifade etmektedir, o dağılımdaki yaygınlık durumu ile ilgilenmemektedir. Varyasyon katsayısı (CV); bir dağılımın standart sapmasının, dağılımın ortalamasını baz alarak gösterdiği değişimdir, yüzde olarak hesaplanmaktadır. Varyasyon katsayısının (CV) formülü Denklem (3.5)' de gösterilmiştir. CV; varyans katsayısı,  $\sigma$ ; standart sapma,  $\bar{x}$ ; aritmetik ortalama olmak üzere,

$$CV = 100 \frac{\sigma}{\bar{x}} \quad (3.5)$$

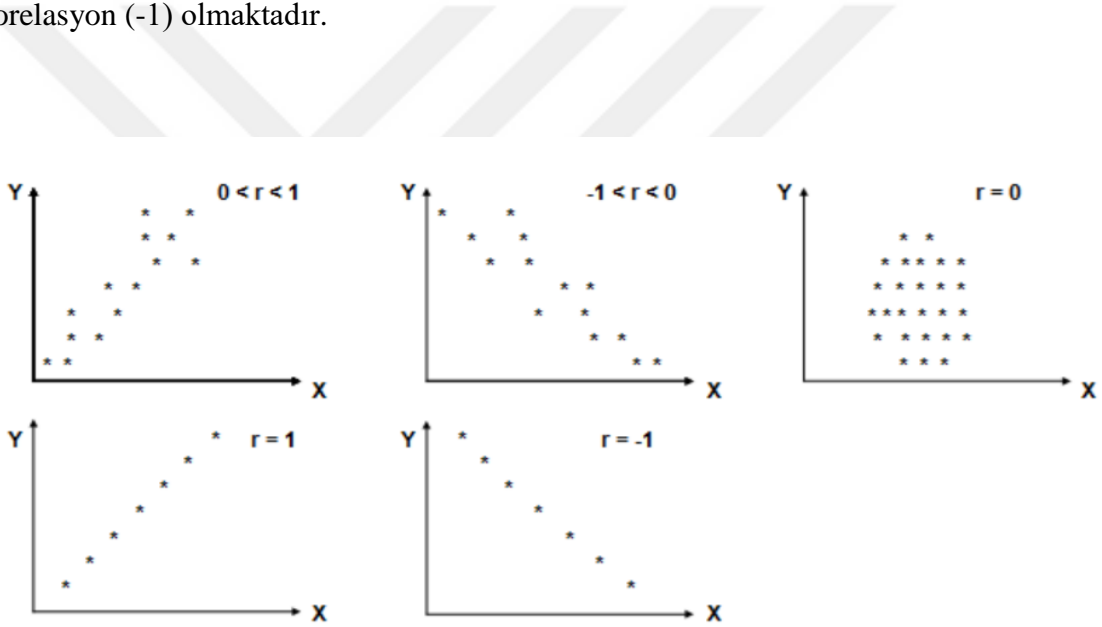
Varyasyon katsayısı aynı zamanda standart sapmanın karesidir.

### 3.2.3.4. Korelasyon

İki veya ikiden fazla değişkenin, aralarında doğrusal bir ilişkinin varlığının, var ise bu doğrusal ilişkinin yön ve şiddeti hakkında bilgi veren istatistiksel metoda 'Korelasyon' adı verilmektedir. Korelasyon katsayısı (r); var olan doğrusal ilişkinin derecesini hesaplar. Korelasyon katsayısı  $[(-1) - (+1)]$  arasında değişen değerlere sahiptir. Korelasyon katsayısının formülü Denklem (3.6)'da tanımlanmıştır.

$$r = \frac{\sum x_i y_i - \frac{\sum x_i \sum y_i}{n}}{\sqrt{\left( \sum x_i^2 - \frac{(\sum x_i)^2}{n} \right) \left( \sum y_i^2 - \frac{(\sum y_i)^2}{n} \right)}} \quad (3.6)$$

Korelasyon pozitif (+) iken bu iki veya daha fazla deęişken aynı yönde bir ilişkiye sahiptir anlamına gelmektedir. Korelasyon negatif (-) iken bu iki veya daha fazla deęişken zıt yönde bir ilişkiye sahiptir anlamına gelmektedir. Bu deęişkenler pozitif veya negatif yönlü bir ilişkiye sahip deęilse aralarında korelasyon ilişkisi yoktur demektir, korelasyon sıfır olmaktadır. Eđer deęişkenler arasında %100 pozitif bir ilişki var ise korelasyon (+1) olmaktadır veya %100 negatif bir ilişki var ise o zaman korelasyon (-1) olmaktadır.



Şekil 3.9. Farklı korelasyon durumları


### 3.2.3.5. Çarpıklık

Bir rasgele sürece ait olasılık dağılımının asimetrikliğinin ölçüsüne bu dağılımın çarpıklığı denilmektedir. Bir dağılımın çarpıklığı, ölçüm sonuçlarının dağılımı hakkında bilgi vermektedir, Denklem (3.7)' de tanımlanmıştır:


$$ÇK = \frac{\sum_{i=1}^n (x_i - \bar{x})^3 / n}{S^3} \quad (3.7)$$

$\bar{x}$ ;  $x$ 'in aritmetik ortalamasını,  $S$ ;  $x$ 'in standart sapmasını,  $n$ ; örnek sayısını,  $\text{ÇK}$  çarpıklık katsayısının değerini temsil etmektedir.


Çarpıklık katsayısı negatif olduğunda, veriler daha çok ortalamamanın soluna doğru yayılmakta, sola çarpık ve negatif yöne eğilimli olmaktadır (Şekil 3.12). Çarpıklık katsayısı pozitif olduğunda, veriler daha çok ortalamamanın sağına doğru yayılmakta, sağa çarpık ve pozitif yöne eğilimli olmaktadır (Şekil 3.11). Normal dağılımın (veya mükemmel simetrik dağılımın) çarpıklığı sıfır olmakta, dağılım simetrik olmaktadır (Şekil 3.10).



Şekil 3.10. Çarpıklık katsayısı ( $\text{ÇK}$ ) = 0 olduğu durumda dağılım simetrik olmaktadır



Şekil 3.11. Çarpıklık katsayısı ( $\text{ÇK}$ ) < 0 olduğu durumda dağılım sola çarpık yada (-) yöne eğilimli olmaktadır



Şekil 3.12. Çarpıklık katsayısı ( $\text{ÇK}$ ) > 0 olduğu durumda dağılım sağa çarpık yada (+) yöne eğilimli olmaktadır

### 3.2.3.6. Basıklık


Basıklık dağılımın normal dağılımdan daha basık veya sivri olması durumunu ifade etmektedir, bir dağılımın ne kadar aşırı derecede eğilimli olduğunun bir ölçüsüdür. Momentlerle hesaplanan dağılımın basıklığının normal dağılıma uyup uymadığının

araştırıldığı ölçüye basıklık ölçüsü denir. Basıklık bir veri setindeki değişim miktarının göstergesidir. Normal dağılımın basıklık katsayısı sıfır olmaktadır (Şekil 3.13). Normal dağılımdan daha belirgin olan dağılımların basıklığı 0'dan büyük (Şekil 3.15); daha az aykırı eğilimli olan dağılımların basıklığı ise 0'dan daha düşük olmaktadır (Şekil 3.14).


Bir dağılımın basıklığı Denklem (3.8)' de tanımlanmıştır:

$$BK = \frac{\sum_{i=1}^n (x_i - \bar{x})^4 / n}{S^4} - 3 \quad (3.8)$$


$\bar{x}$ ;  $x$ ' in aritmetik ortalamasını,  $S$ ;  $x$ ' in standart sapmasını,  $n$ ; örnek sayısını  $BK$  basıklık katsayısının değerini temsil etmektedir.



Şekil 3.13. Basıklık katsayısı (BK) = 0 ise dağılımın yüksekliği standart normal dağılıma uygundur



Şekil 3.14. Basıklık katsayısı (BK) < 0 ise dağılım standart normal dağılımdan daha basıktır



Şekil 3.15. Basıklık katsayısı (BK) > 0 ise dağılım standart normal dağılımdan daha sivridir



### 3.2.3.7. Enerji

Enerji, yoğunluk seviyesi dağılımının tek düzeliğini ölçmektedir ve aynı zamanda sinyal gücünün bir ölçüsüdür. Değer yüksekse dağılım yoğunluk seviyesi düşük olmaktadır (Sergyan S., 2008; Selvarajah S., 2011; Alnihoud J., 2012). Enerji formülü Denklem (3.9)'da gösterildiği gibidir.

$$Energy = \sqrt{\sum S(i)^2} \quad (3.9)$$

### 3.2.3.8. Entropi

Entropi; kavram olarak tahmini 150 yıldır bilimde varlığını korumaktadır ve çeşitli şekillerde yorumlanmıştır. Fizikle ilgilenen Rudolf Julius Emmanuel Clausius (1822- 1888) entropiyi kavram olarak ilk ortaya atan ve kullan bilim insanı olmuştur. Daha sonralarda yine aynı şekilde fizikle ilgilenen Ludwig Boltzmann (1822- 1888) entropi ve olasılık kavramlarını bir arada kullanmıştır. Claude Elwood Shannon (1916- 2001); Ludwig Boltzmann'ın formülasyonu ile yakın bir kavram olarak bu tez çalışmasında da kullanılan bir entropi kavramı ve formülü elde etmiştir. Shannon C. E; 1948 yılında entropiyi; bilgi veya belirsizlik ölçütü olarak istatistikte kullanmak üzere ortaya atmıştır. Bu kavram bir sistemin icerdiği bilginin kaybedilmeden ne kadar sıkıştırılabileceğine dair bize bir üst sinir vermektedir.

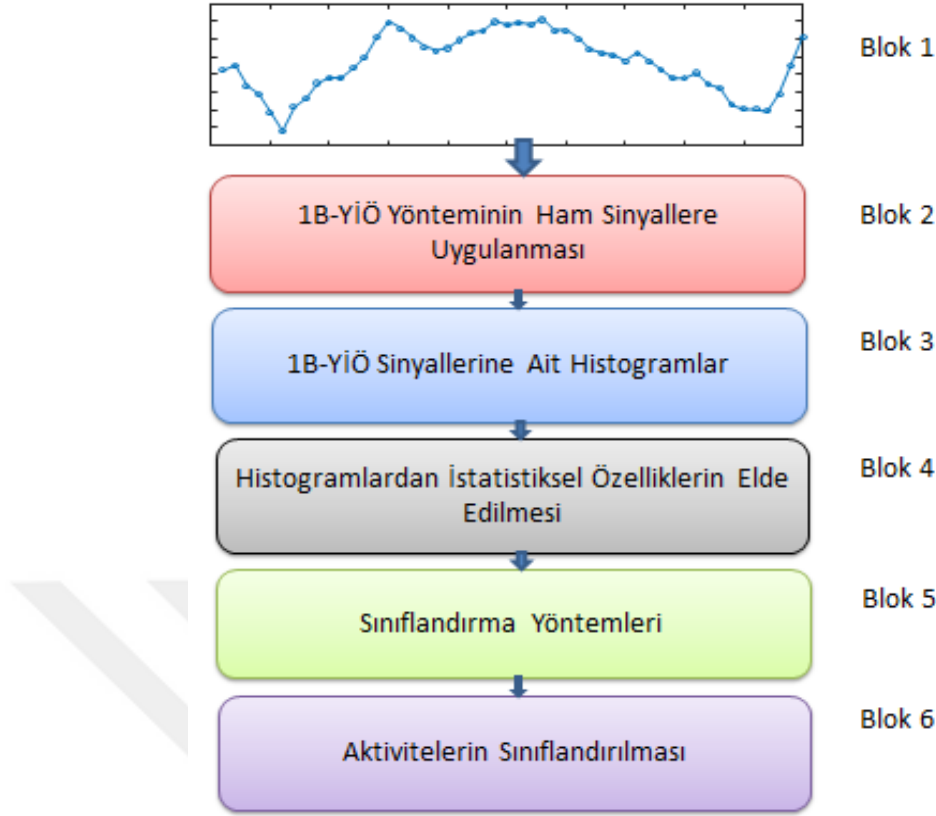
Bu çalışmada kullanılan entropi; sinyaldeki düzenin veya düzensizliğinin ölçütü olarak ifade edilmiştir. Entropi tahmini için ilk aşama; histogramın elde edilmesidir, daha sonra entropi hesaplanabilmektedir. Shannon'a göre formülasyonu Denklem (3.10)'da görüldüğü gibidir (Shannon C. E., 1948).

$$H(X) = -\sum_{i=1}^n p_i \log p_i \quad (3.10)$$

Burada  $P = \{p_1, p_2, \dots, p_n\}$ ; X değişkenin olasılık dağılımını vermektedir.  $H(X)$ ; X değişkeninin entropisidir.

### 3.2.4. Çalışma diyagramı

Bu çalışmada hareket tanıma için farklı bir yaklaşım yöntemi önerilmiştir. Önerilen yaklaşım yöntemine ait blok diyagramı Şekil 3.16'da verilmiştir.



Şekil 3.16. Önerilen yöntemin blok şeması

**1. Blok:** UCI kütüphanesinde yer alan Mhealth veri tabanından alınan ham sensör sinyal değerleri kullanılmaktadır. Sinyaller anlaşılabilir yorumlanamaz haldedirler.

**2. Blok:** Bu aşamada ham sensör sinyallerine 1B-YİÖ dönüşümü uygulanmıştır (Şekil 3.4). Dönüşüm sonucunda 0-255 değerleri arasında değişen değerler elde edilmiştir. Bu değerlerden elde edilen sinyallere ise 1B-YİÖ sinyalleri adı verilmektedir. Bu sinyaller incelendiğinde ham sinyallere oranla daha anlamlı bir duruş sergilediğini görülmektedir. Çünkü karışık ve uç değerlere sahip olan ham sinyaller belirli değerlerin arasına indirgenmiş ve hareket ayrıştırma daha belirgin bir hale dönüşmüş olur.

**3. Blok:** Bu adımda, her bir değer için ilgili sinyalde ne sıklıkla görüldüğünü gösteren, 1B-YİÖ sinyallerinin histogramları belirlenmiştir. Histograma ait değerlerin her biri, bir özelliği ifade etmektedir. Bu çalışmada  $P=8$  değerini aldığından, sınıflandırma yöntemleri için 256 özellik elde edilmiştir.

**4. Blok:** Bu çalışmada hareketleri sınıflandırmak için ayırt ediciliği yüksek olacağı düşünülen çeşitli istatistiksel özellikler çıkarılmıştır. Bu özellikler hareket

sınıflandırmanın kalitesini arttırıp, daha yüksek doğruluklu sonuçlar elde edilmesini sağlamaktadırlar. İsaletli öznitelikler seçildiği takdirde, sınıflandırma aşamasında kullanılmış olan algoritmanın çalışma hızı artmakta, zamandan tasarruf sağlanmakta ve fazladan hafıza kullanımı engellenmektedir. Uygun öznitelikler elde edildiğinde doğal olarak bir miktar veri kaybolmaktadır, fakat geriye kalan, kullanılacak olan veri; güvenilirliği yüksek, ayırıştırma kabiliyeti fazlaca olan veri olmalıdır. Böylece yüksek sınıflandırma başarısına sahip, kaliteli bir sınıflandırma olanağı sağlanmış olur. Hareketleri sınıflandırırken elde edilen öznitelikler; ortalama, standart sapma, enerji, entropi, çarpıklık, basıklık, varyasyon katsayısı, korelasyon katsayısı, minimum, maksimum, medyan ve ardışık mutlak farklardır.

**5. Blok:** Hareketleri sınıflandırmak için çeşitli makine öğrenmesi yöntemleri kullanılmıştır. Bu sınıflandırma yöntemleri uygulandığında başarılı olanlar, daha az başarılı olanlar, rahatlıkla birbirinden ayırt edilebilen hareketler, birbirinden ayırt edilmesi biraz daha zor olan hareketler incelenip tartışılmıştır. Sınıflandırma işlemi; on katlı çapraz doğrulama yöntemine bağlı olarak gerçekleştirilmiştir.

**6. Blok:** Sınıflandırma sonuçları paylaşılmıştır.

### 3.2.5. Sınıflandırma

Sınıflandırma, daha doğru öngörü ve analizde yardımcı olmak için bir veri kümesine kategoriler atayan bir veri madenciliği tekniğidir. Sınıflandırma, büyük veri kümelerinin analizini etkili kılmak için tasarlanmış birkaç yöntemden biridir. Sınıflandırma işleminin nasıl çalıştığına bakılacak olursa; hedef, bir soruyu cevaplayacak, karar verebilecek veya davranışları öngören bir dizi ayırıştırma kuralları oluşturmaktır. Başlamak için, belirli bir özellik kümesi ve olası sonucu içeren bir dizi eğitim verisi geliştirilmiştir. Sınıflandırma algoritmasının görevi, bu özellik kümesinin sonuçlarına nasıl ulaştığını keşfetmektir. İki aşamadan birincisinde; verilen eğitim setinden bu dağılımın şekli öğrenilmektedir ve ikincisinde; sınıfı belli olmayan test verileri en uygun bir biçimde sınıflandırmaya çalışılmaktadır.

Sınıflandırmada verinin dağılımına göre bir model tespit edilmektedir ve bulunan model, başarısı belirlendikten sonra niteliğin gelecekteki ya da bilinmeyen değerini tahmin etmek için kullanılmaktadır.

Bu çalışmada on iki adet hareketin en yüksek doğruluklarla sınıflandırılması amaçlanmıştır. On iki hareketin her birinden etkili öznitelikler elde edilerek bu öznitelikler üzerinden sınıflandırma yapılmıştır. Naive Bayes, Random Forest, Random Committee gibi farklı sınıflandırma algoritmaları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

### 3.2.6. Performans ölçütleri

Model başarısı değerlendirildiğinde bazı kavramlar bilinmelidir. Bunlar; hata oranı, kesinlik, duyarlılık ve f-ölçütüdür. Modelin başarısı doğru sınıflandırılan verilerin sayıları ile yanlış sınıflandırılan verilerin sayıları baz alınarak ölçülmektedir.

Sınıflandırma işlemi sona erdiğinde elde edilen sonuçlar karışıklık matrisinde belirtilmektedir. Matriste yer alan satır verileri; test setindeki verilerin gerçek adetlerini, sütunlar ise tahminleri göstermektedir.

**Tablo 3.3.** Performans Ölçütleri

	Tahmin edilen sınıflar	
	Class=1	Class=0
Class=1	x	y
Class=0	w	z

x; TP (Doğru pozitif), y; FN (Yanlış negatif), w; FP (Yanlış Pozitif), z; TN (Doğru Negatif)'dir.

#### 3.2.6.1. Doğruluk (Accuracy)-Hata oranı (Error rate)

Bir modelin başarısı ölçüleceği zaman bu modelin doğruluk oranı kullanılmaktadır. Sınıflandırması doğru olarak yapılmış olan veri adedinin (TN +TP), veri setindeki tüm verilerin adedine (FP+FN+TP+TN) oranına 'Doğruluk Oranı' denir (Denklemler (3.11)).

Sınıflandırması yanlış olarak yapılmış olan veri adedinin (FN+FP), veri setindeki tüm verilerin adedine (FP+FN+TP+TN) oranına 'Hata oranı' denir (Denklem (3.12)).

$$D = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.11)$$

$$HO = \frac{FP + FN}{TP + FP + FN + TN} \quad (3.12)$$

*D*; Doğruluk, *HO*; Hata oranıdır.

### 3.2.6.2. Kesinlik (Precision)

Kesinlik; sınıflandırıcının olumlu bir sınıf olarak ilan ettiği grupta aslında olumlu çıktığı kayıtların oranı olarak tanımlanmaktadır (Denklem (3.13)).

$$P = \frac{TP}{TP + FP} \quad (3.13)$$

*P*; Kesinlik.

### 3.2.6.3. Duyarlılık (Recall)

Duyarlılık, aslında ilgili alt gruba ait tüm örnekler arasındaki doğru örneklerin oranı olarak hesaplanmaktadır (Denklem (3.14)).

$$R = \frac{TP}{TP + FN} \quad (3.14)$$

*R*; Duyarlılık.

### 3.2.6.4. F-Ölçütü (F-Measure)

Duyarlılık ve Kesinlik tanımları ışığında F-Ölçütü; bu değerlerin harmonik ortalamasıdır (Denklem (3.15)).


$$F - Measure = \frac{2 \times R \times P}{R + P} \quad (3.15)$$

*F-Measure*; F-Ölçütü, *R*; Duyarlılık, *P*; Kesinliktir.


## 4. BULGULAR

### 4.1. 1B-YİÖ Histogramları


Göğüs kısmına takılan sensörden elde edilen sinyal için 4 farklı aktivite için örnekler Şekil 4.1, Şekil 4.2, Şekil 4.3 ve Şekil 4.4'te verilmiştir. Bu aktiviteler uzanma, öne eğilme, bisiklet sürme ve öne-arkaya zıplama şeklindedir. Şekillerde ayrıca bu aktivitelerden oluşturulan 1B-YİÖ histogramları da verilmiştir. Bu histogramlardan bu aktivitelerin birbirinden ayrıldığı görülmektedir. Aktivitelerin sınıflandırılması için çalışmada kullanılan istatistiksel özellikler bu 1B-YİÖ sinyallerinden elde edilmiştir.




Şekil 4.1. Uzanma aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı



Şekil 4.2. Öne eğilme aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı



Şekil 4.3. Bisiklet sürme aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı



Şekil 4.4. Öne arkaya zıplama aktivitesine ait örnek sinyal ve 1B-YİÖ histogramı

## 4.2. Başarı Oranları

Hareket işaretlerinden elde edilen öznelikler kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırma metotları olarak Naive Bayes (NB), Random Committee (RC) ve Random Forest (RF) kullanılmıştır. Sınıflandırma işlemleri için açık kaynak bir yazılım olan WEKA kullanılmış, 10-katlı çapraz geçerlilik testine göre sınıflandırma gerçekleştirilmiştir. Yukarıdaki üç sınıflandırma metodu ile elde edilen karışıklık matrisleri ve performans oranları Tablo 4.1 ve Tablo 4.6 arasındaki tablolarda verilmiştir.

**Tablo 4.1.** RF sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>10</b>	0	0	0	0	0	0	0	0	0	0	0
L2	2	<b>6</b>	2	0	0	0	0	0	0	0	0	0
L3	0	2	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>10</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	1	1	0	<b>8</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>9</b>	1	0
L11	0	0	0	0	0	0	0	0	0	1	<b>9</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.2.** RF sınıflandırma metodu için performans sonuçları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,600	0,018	0,750	0,600	0,667
L3	0,800	0,018	0,800	0,800	0,800
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,009	0,900	0,900	0,900
L11	0,900	0,009	0,900	0,900	0,900
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,917</b>	<b>0,008</b>	<b>0,917</b>	<b>0,917</b>	<b>0,914</b>

Tablo 4.1 ve Tablo 4.2'ye bakıldığında L1 (hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) aktivitesi için bulunulmuştur. L2 hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak yüksek sınıflandırma başarısı gözlenmiştir. RF ile sınıflandırma başarı %91,7 olarak gözlenmiştir.



**Tablo 4.3.** RC sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>10</b>	0	0	0	0	0	0	0	0	0	0	0
L2	2	<b>5</b>	3	0	0	0	0	0	0	0	0	0
L3	0	2	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>10</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	1	0	0	<b>9</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>9</b>	1	0
L11	0	0	0	0	0	0	0	0	0	0	<b>10</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.4.** RC sınıflandırma metodu için performans sonuçları

Sınıflar	Doğru pozitif oranı (TP rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,500	0,018	0,714	0,500	0,588
L3	0,800	0,027	0,727	0,800	0,762
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,000	1,000	0,900	0,947
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,925</b>	<b>0,007</b>	<b>0,924</b>	<b>0,925</b>	<b>0,922</b>

Tablo 4.3 ve Tablo 4.4’de bakıldığında L1 (hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak yüksek sınıflandırma işlemi gözlenmiştir. RC ile sınıflandırma başarı %92,5 olarak gözlenmiştir.

**Tablo 4.5.** NB sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>9</b>	1	0	0	0	0	0	0	0	0	0	0
L2	2	<b>4</b>	4	0	0	0	0	0	0	0	0	0
L3	0	2	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	1	<b>9</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	0	2	0	<b>8</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>10</b>	0	0
L11	0	0	0	0	0	0	0	0	0	0	<b>10</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.6.** NB sınıflandırma metodu için performans sonuçları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,018	0,818	0,900	0,857
L2	0,400	0,027	0,571	0,400	0,471
L3	0,800	0,036	0,667	0,800	0,727
L4	1,000	0,009	0,909	1,000	0,952
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,018	0,833	1,000	0,909
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,000	1,000	1,000	1,000
L11	1,000	0,000	1,000	1,000	1,000
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,900</b>	<b>0,009</b>	<b>0,900</b>	<b>0,900</b>	<b>0,896</b>

Tablo 4.5 ve Tablo 4.6'ya bakıldığında L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 hareketi başarı oranı %40 olarak görülmektedir. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak yüksek sınıflandırma işlemi gözlenmiştir. NB ile sınıflandırma başarı %90 olarak gözlenmiştir. Tüm özneliklerin kullanılarak NB, RF ve RC için gözlenen başarı oranları Tablo 4.7'de verilmiştir. Bu üç yöntemden RC en başarılı sınıflandırıcı olarak gözlenmiştir. Ancak diğer metotların da başarısı yüksektir.

**Tablo 4.7.** Sınıflandırıcıların performans oranları

Sınıflandırıcılar	Başarı Oranı
Random Committee	%92,50
Random Forest	%91,66
Naive Bayes	%90,00

### 4.3. Sensör Türlerine Göre Başarı Oranları

Bu çalışmada kullanılan ivme, çayro, manyometre sensörlerinden ve EEG sinyallerinden elde edilen özneteliklerini kullanarak RF, RC ve NB sınıflandırıcılar ile sınıflandırma işlemleri gerçekleştirilmiştir. Bu bölümde amaç sensör türlerin hareket tanımadaki etkilerini göstermektir. Elde edilen karışıklık matrisleri ve performans oranları Tablo 4.8 ve Tablo 4.13 arasındaki tablolarda verilmiştir.

**Tablo 4.8.** İvme sensörleri için RC ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>10</b>	0	0	0	0	0	0	0	0	0	0	0
L2	2	<b>6</b>	2	0	0	0	0	0	0	0	0	0
L3	1	2	<b>7</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>9</b>	1	0	0	0	0	0	0	0
L5	0	0	0	0	<b>9</b>	0	0	1	0	0	0	0
L6	0	0	0	0	0	<b>9</b>	0	1	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	0	2	0	<b>8</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>7</b>	3	0
L11	0	0	0	0	0	0	0	0	0	2	<b>8</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.9.** İvme sensörleri için RC ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,027	0,769	1,000	0,870
L2	0,600	0,018	0,750	0,600	0,667
L3	0,700	0,018	0,778	0,700	0,737
L4	0,900	0,000	1,000	0,900	0,947
L5	0,900	0,009	0,900	0,900	0,900
L6	0,900	0,018	0,818	0,900	0,857
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,018	0,800	0,800	0,800
L9	1,000	0,000	1,000	1,000	1,000
L10	0,700	0,018	0,778	0,700	0,737
L11	0,800	0,027	0,727	0,800	0,762
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,858</b>	<b>0,013</b>	<b>0,860</b>	<b>0,858</b>	<b>0,856</b>

Sadece ivme sensörlerden elde edilen öznitelikler kullanılarak %85,8 başarı oranı gözlenmiştir. Tablo 4.8 ve Tablo 4.9'a bakıldığında L1 (hareketsiz durma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) aktivitesi için bulunulmuştur. L2 hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Yüksek sınıflandırma başarısı gözlenmiştir.

**Tablo 4.10.** Cayro (Gyro) sensörleri için RC ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>8</b>	1	1	0	0	0	0	0	0	0	0	0
L2	2	<b>5</b>	3	0	0	0	0	0	0	0	0	0
L3	0	3	<b>7</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>9</b>	0	0	1	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	0	1	0	<b>9</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>10</b>	0	0
L11	0	0	0	0	0	0	0	0	0	3	<b>7</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.11.** Cayro (Gyro) sensörleri için RC ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,800	0,018	0,800	0,800	0,800
L2	0,500	0,036	0,556	0,500	0,526
L3	0,700	0,036	0,636	0,700	0,667
L4	1,000	0,000	1,000	1,000	1,000
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,027	0,769	1,000	0,870
L11	0,700	0,000	1,000	0,700	0,824
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,875</b>	<b>0,011</b>	<b>0,881</b>	<b>0,875</b>	<b>0,874</b>

Sadece Cayro sensörlerden elde edilen öznitelikler kullanılarak %87,5 başarı oranı gözlenmiştir. Tablo 4.10 ve Tablo 4.11'e bakıldığında L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu yürüyüş) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 (oturma ve rahatlama)

hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak yüksek sınıflandırma başarısı gözlenmiştir.

**Tablo 4.12.** Manyometre (Magnetometer) sensörleri için RC ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>8</b>	1	1	0	0	0	0	0	0	0	0	0
L2	2	<b>6</b>	2	0	0	0	0	0	0	0	0	0
L3	0	1	<b>9</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>9</b>	0	0	1	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	0	0	0	<b>10</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>7</b>	3	0
L11	0	0	0	0	0	0	0	0	0	2	<b>8</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.13.** Manyometre (Magnetometer) sensörleri için RC ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik(Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,800	0,018	0,800	0,800	0,800
L2	0,600	0,018	0,750	0,600	0,667
L3	0,900	0,027	0,750	0,900	0,818
L4	1,000	0,000	1,000	1,000	1,000
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,009	0,909	1,000	0,952
L9	1,000	0,000	1,000	1,000	1,000
L10	0,700	0,018	0,778	0,700	0,737
L11	0,800	0,027	0,727	0,800	0,762
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,892</b>	<b>0,010</b>	<b>0,893</b>	<b>0,892</b>	<b>0,890</b>

Sadece Manyometre sensörlerden elde edilen öznelikler kullanılarak %89,2 başarı oranı gözlenmiştir. Tablo 4.12 ve Tablo 4.13'e bakıldığında L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak yüksek sınıflandırma başarısı gözlenmiştir.

**Tablo 4.14.** EEG işaretleri için RC ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>4</b>	4	1	0	0	0	0	0	0	0	0	0
L2	5	<b>1</b>	4	0	0	0	0	0	0	0	0	0
L3	1	2	<b>7</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>9</b>	0	0	1	0	0	0	0
L6	0	0	0	0	0	<b>8</b>	0	2	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	1	2	0	<b>7</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>7</b>	3	0
L11	0	0	0	0	0	0	0	0	0	3	<b>7</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.15.** EEG işaretleri için RC ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,400	0,055	0,400	0,400	0,400
L2	0,100	0,055	0,143	0,100	0,118
L3	0,700	0,045	0,583	0,700	0,636
L4	1,000	0,000	1,000	1,000	1,000
L5	0,900	0,009	0,900	0,900	0,900
L6	0,800	0,018	0,800	0,800	0,800
L7	1,000	0,009	0,909	1,000	0,952
L8	0,700	0,027	0,700	0,700	0,700
L9	1,000	0,000	1,000	1,000	1,000
L10	0,700	0,027	0,700	0,700	0,700
L11	0,700	0,027	0,700	0,700	0,700
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,750</b>	<b>0,023</b>	<b>0,736</b>	<b>0,750</b>	<b>0,742</b>

EEG işaretlerinden elde edilen öznelikler kullanılarak %89,2 başarı oranı gözlenmiştir. Tablo 4.14 ve Tablo 4.15'e bakıldığında L4 (yürüme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 hareketi için EEG işaretlerinden gözlenen başarının çok kötü olduğu görülmüştür. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir.

İvme, Cayro, Manyometre ve EEG sensör ve işaretlerden elde edilen öznelikler kullanılarak RC ile sınıflandırma işlemleri gerçekleştirilmiştir. Başarı oranları Tablo 4.16' da verilmiştir. Tabloya bakıldığında en yüksek başarı oranı Manyometre sensörlerden elde edilen öznelikler ile elde edilmiştir. En düşük başarı EEG

işaretlerden elde edilen öznelikler ile gözlenmiştir. Ancak EEG için düşük başarı oranı deneklerdeki EEG kanal sayısının azlığından kaynaklanmıştır.

**Tablo 4.16.** Kullanılan sensörlerin sınıflandırmadaki toplam başarı oranları

Sensörler	Başarı Oranı
Cayro sensör	%87,50
Magnometer	%89,16
Ivme	%85,83
EEG sinyalleri	%75,00

#### 4.4. Eksenlere Göre Başarı Oranları

Bu bölümde kullanılan sensörlerin X, Y ve Z eksenlerine göre elde edilen öznelikler kullanılarak RC sınıflandırma metodu ile elde edilen sonuçlar tartışılmıştır. Eksenler için gözlenen sonuçlar Tablo 4.17 ve Tablo 4.22 arasındaki tablolarda verilmiştir. Bu bölümde amaç sensörlerin eksen başarılarını açıklamaktır. Sınıflandırma işlemleri RC metodu ile gerçekleştirilmiştir.

**Tablo 4.17.** Sensörlerin X ekseninden elde edilen öznelikler ile gözlenen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>10</b>	0	0	0	0	0	0	0	0	0	0	0
L2	2	<b>6</b>	2	0	0	0	0	0	0	0	0	0
L3	0	2	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	1	<b>8</b>	0	0	0	0	0	1	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	1	0	0	<b>9</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>10</b>	0	0
L11	0	0	0	0	0	0	0	0	0	0	<b>10</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.18.** Sensörlerin X ekseninden elde edilen özniteliklerin performansları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,600	0,018	0,750	0,600	0,667
L3	0,800	0,018	0,800	0,800	0,800
L4	1,000	0,009	0,909	1,000	0,952
L5	0,800	0,009	0,889	0,800	0,842
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,000	1,000	1,000	1,000
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,925</b>	<b>0,007</b>	<b>0,924</b>	<b>0,925</b>	<b>0,922</b>

Sensörlerin X eksenlerinden elde edilen öznitelikler kullanılarak RC ile %92,5 başarı oranı gözlenmiştir. Tablo 4.17 ve Tablo 4.18'e bakıldığında L1 (hareketsiz durma), L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu yürüyüş yapma), L11 (koşma) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak X eksenindeki öznitelikler için yüksek başarı oranları gözlenmiştir.

**Tablo 4.19.** Sensörlerin Y ekseninden elde edilen öznitelikler ile gözlenen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>9</b>	1	0	0	0	0	0	0	0	0	0	0
L2	2	<b>6</b>	2	0	0	0	0	0	0	0	0	0
L3	0	3	<b>7</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>10</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	1	1	0	<b>8</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>9</b>	1	0
L11	0	0	0	0	0	0	0	0	0	1	<b>9</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>



**Tablo 4.20.** Sensörlerin Y ekseninden elde edilen özniteliklerin performansları

Sınıflar	Doğru pozitif oranı (TP rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,018	0,818	0,900	0,857
L2	0,600	0,036	0,600	0,600	0,600
L3	0,700	0,018	0,778	0,700	0,737
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,009	0,900	0,900	0,900
L11	0,900	0,009	0,900	0,900	0,900
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,900</b>	<b>0,009</b>	<b>0,901</b>	<b>0,900</b>	<b>0,899</b>

Sensörlerin Y eksenlerinden elde edilen öznitelikler kullanılarak RC ile %90 başarı oranı gözlenmiştir. Tablo 4.19 ve Tablo 4.20'ye bakıldığında L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (Uzanma) hareketlerine benzetilmiştir. Genel olarak Y eksenindeki öznitelikler için yüksek başarı oranları gözlenmiştir.

**Tablo 4.21.** Sensörlerin Z ekseninden elde edilen öznitelikler ile gözlenen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>9</b>	1	0	0	0	0	0	0	0	0	0	0
L2	3	<b>4</b>	3	0	0	0	0	0	0	0	0	0
L3	0	2	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>10</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>9</b>	0	1	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	1	0	0	<b>9</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>9</b>	1	0
L11	0	0	0	0	0	0	0	0	0	3	<b>7</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.22.** Sensörlerin Z ekseninden elde edilen özniteliklerin performansları

Sınıflar	Doğru pozitif oranı (TP rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,027	0,750	0,900	0,818
L2	0,400	0,027	0,571	0,400	0,471
L3	0,800	0,027	0,727	0,800	0,762
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	0,900	0,000	1,000	0,900	0,947
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,027	0,750	0,900	0,818
L11	0,700	0,009	0,875	0,700	0,778
L12	0,875	0,011	0,874	0,875	0,871
<b>Ortalama</b>	<b>0,875</b>	<b>0,011</b>	<b>0,874</b>	<b>0,875</b>	<b>0,871</b>

Sensörlerin Z eksenlerinden elde edilen öznitelikler kullanılarak RC ile %87,5 başarı oranı gözlenmiştir. Tablo 4.21 ve Tablo 4.22'ye bakıldığında L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma) ve L9 (bisiklet sürme) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 aktivitesi için bulunulmuştur. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Genel olarak Z eksenindeki öznitelikler için yüksek başarı oranları gözlenmiştir.

Sensörlerin X, Y ve Z eksenlerden elde edilen özniteliklerin genel başarısına bakıldığında X ekseninden çıkarılan öznitelikler ile daha yüksek başarı oranları gözlenmiştir. X, Y ve Z eksenleri için sırayla %92,5, %90 ve %87,5 başarı oranları gözlenmiştir.

**Tablo 4.23.** Eksenlere göre başarı oranları

Eksenler	Başarı Oranı
X	%92,50
Y	%90,00
Z	%87,50

#### 4.5. İstatistiksel Özelliklere Göre Başarı Oranları

Bu bölümde sensörlerden elde edilen istatistiksel özniteliklerin her biri için gözlenen başarı oranları incelenmiştir. İstatistiksel özniteliklerin ayrı ayrı hareket tanımadaki etkileri incelenmiştir. Elde edilen karışıklık matrisleri ve performanslar Tablo 4.24 ve Tablo 4.48 arasındaki tablolarda verilmiştir.

**Tablo 4.24.** Ortalama öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	5	2	3	0	0	0	0	0	0	0	0	0
L2	4	4	2	0	0	0	0	0	0	0	0	0
L3	7	1	2	0	0	0	0	0	0	0	0	0
L4	0	0	0	9	1	0	0	0	0	0	0	0
L5	0	0	0	1	6	2	0	1	0	0	0	0
L6	0	0	0	0	1	7	0	2	0	0	0	0
L7	0	0	0	0	0	0	9	1	0	0	0	0
L8	0	0	0	0	0	3	0	7	0	0	0	0
L9	0	0	0	0	0	0	0	2	8	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	2	5	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

**Tablo 4.25.** Ortalama öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,500	0,100	0,313	0,500	0,385
L2	0,400	0,027	0,571	0,400	0,471
L3	0,200	0,045	0,286	0,200	0,235
L4	0,900	0,027	0,750	0,900	0,818
L5	0,600	0,027	0,667	0,600	0,632
L6	0,700	0,045	0,583	0,700	0,636
L7	0,900	0,000	1,000	0,900	0,947
L8	0,700	0,055	0,538	0,700	0,609
L9	0,800	0,000	1,000	0,800	0,889
L10	0,800	0,018	0,800	0,800	0,800
L11	0,500	0,018	0,714	0,500	0,588
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,667</b>	<b>0,030</b>	<b>0,685</b>	<b>0,667</b>	<b>0,667</b>

Sensörlerden elde edilen istatistiksel özniteliklerin ortalama özniteliği kullanılarak NB ile %66,7 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile düşük başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir.

**Tablo 4.26.** Standart sapma öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>1</b>	5	3	0	0	0	0	0	0	0	0	0
L2	3	<b>5</b>	2	0	0	0	0	0	0	0	0	0
L3	3	1	<b>5</b>	0	0	0	0	0	0	0	1	0
L4	0	0	0	<b>5</b>	3	0	0	0	0	1	1	0
L5	0	0	0	3	<b>6</b>	0	0	0	0	0	0	0
L6	0	0	0	0	2	<b>4</b>	0	3	0	0	1	0
L7	0	0	0	0	0	1	<b>7</b>	2	0	0	0	0
L8	0	0	0	0	0	3	1	<b>5</b>	0	1	0	0
L9	0	0	0	2	1	0	0	0	<b>6</b>	0	1	0
L10	0	0	0	1	2	0	0	0	0	<b>2</b>	5	0
L11	0	0	0	0	0	0	0	0	0	3	<b>7</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.27.** Standart sapma öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,100	0,055	0,143	0,100	0,118
L2	0,500	0,055	0,455	0,500	0,476
L3	0,500	0,045	0,500	0,500	0,500
L4	0,500	0,055	0,455	0,500	0,476
L5	0,600	0,073	0,429	0,600	0,500
L6	0,400	0,036	0,500	0,400	0,444
L7	0,700	0,018	0,778	0,700	0,737
L8	0,500	0,055	0,455	0,500	0,476
L9	0,600	0,000	1,000	0,600	0,750
L10	0,200	0,045	0,286	0,200	0,235
L11	0,700	0,082	0,438	0,700	0,538
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,525</b>	<b>0,043</b>	<b>0,536</b>	<b>0,525</b>	<b>0,521</b>

Sensörlerden elde edilen istatistiksel özniteliklerin standart sapma özniteliği kullanılarak NB ile %52,5 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile düşük başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

**Tablo 4.28.** Enerji öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	2	5	3	0	0	0	0	0	0	0	0	0
L2	6	3	0	0	0	0	0	0	1	0	0	0
L3	2	1	3	0	0	0	0	0	4	0	0	0
L4	0	0	0	6	1	0	0	1	0	2	0	0
L5	0	0	0	1	8	0	0	1	0	0	0	0
L6	0	1	0	0	0	3	1	5	0	0	0	0
L7	0	0	1	0	0	2	6	0	1	0	0	0
L8	0	0	0	0	0	3	0	5	0	2	0	0
L9	0	2	0	0	0	0	0	0	7	0	1	0
L10	0	0	0	2	0	0	0	0	0	5	3	0
L11	0	0	0	1	0	1	0	1	0	3	4	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

**Tablo 4.29.** Enerji öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,200	0,073	0,200	0,200	0,200
L2	0,300	0,082	0,250	0,300	0,273
L3	0,300	0,036	0,429	0,300	0,353
L4	0,600	0,036	0,600	0,600	0,600
L5	0,800	0,009	0,889	0,800	0,842
L6	0,300	0,055	0,333	0,300	0,316
L7	0,600	0,009	0,857	0,600	0,706
L8	0,500	0,073	0,385	0,500	0,435
L9	0,700	0,055	0,538	0,700	0,609
L10	0,500	0,064	0,417	0,500	0,455
L11	0,400	0,036	0,500	0,400	0,444
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,517</b>	<b>0,044</b>	<b>0,533</b>	<b>0,517</b>	<b>0,519</b>

Sensörlerden elde edilen istatistiksel özniteliklerin enerji özniteliği kullanılarak NB ile %51,7 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile düşük başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

**Tablo 4.30.** Entropi öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>6</b>	1	2	0	0	0	1	0	0	0	0	0
L2	3	<b>4</b>	3	0	0	0	0	0	0	0	0	0
L3	2	3	<b>5</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>9</b>	1	0	0	0	0	0	0	0
L5	0	0	0	1	<b>8</b>	0	0	1	0	0	0	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	1	<b>9</b>	0	0	0	0	0
L8	0	0	0	0	1	2	0	<b>7</b>	0	0	0	0
L9	0	0	0	0	0	0	0	1	<b>9</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>8</b>	2	0
L11	0	0	0	0	0	0	0	0	0	1	<b>9</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.31.** Entropi öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,600	0,045	0,545	0,600	0,571
L2	0,400	0,036	0,500	0,400	0,444
L3	0,500	0,045	0,500	0,500	0,500
L4	0,900	0,009	0,900	0,900	0,900
L5	0,800	0,018	0,800	0,800	0,800
L6	1,000	0,027	0,769	1,000	0,870
L7	0,900	0,009	0,900	0,900	0,900
L8	0,700	0,018	0,778	0,700	0,737
L9	0,900	0,000	1,000	0,900	0,947
L10	0,800	0,009	0,889	0,800	0,842
L11	0,900	0,018	0,818	0,900	0,857
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,783</b>	<b>0,020</b>	<b>0,783</b>	<b>0,783</b>	<b>0,781</b>

Sensörlerden elde edilen istatistiksel özniteliklerin entropi özniteliği kullanılarak NB ile %78,3 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile yüksek başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) ve L6 (öne eğilme) hareketleri için %100 başarı oranı gözlenmiştir. Diğer hareketler için ortalama başarı oranları gözlenmiştir.

**Tablo 4.32.** Korelasyon öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>4</b>	1	5	0	0	0	0	0	0	0	0	0
L2	2	<b>4</b>	4	0	0	0	0	0	0	0	0	0
L3	4	3	<b>3</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>10</b>	0	0	0	0	0	0	0	0
L5	0	0	0	0	<b>9</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>8</b>	0	2	0	0	0	0
L7	0	0	0	0	0	1	<b>9</b>	0	0	0	0	0
L8	0	0	0	0	0	2	0	<b>7</b>	0	1	0	0
L9	0	0	0	1	0	0	0	0	<b>9</b>	0	0	0
L10	0	0	0	1	0	0	0	0	0	<b>4</b>	5	0
L11	0	0	0	0	0	0	0	0	0	3	<b>6</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.33.** Korelasyon öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,400	0,055	0,400	0,400	0,400
L2	0,400	0,036	0,500	0,400	0,444
L3	0,300	0,082	0,250	0,300	0,273
L4	1,000	0,018	0,833	1,000	0,909
L5	0,900	0,009	0,900	0,900	0,900
L6	0,800	0,027	0,727	0,800	0,762
L7	0,900	0,000	1,000	0,900	0,947
L8	0,700	0,018	0,778	0,700	0,737
L9	0,900	0,000	1,000	0,900	0,947
L10	0,400	0,036	0,500	0,400	0,444
L11	0,600	0,055	0,500	0,600	0,545
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,692</b>	<b>0,028</b>	<b>0,699</b>	<b>0,692</b>	<b>0,692</b>

Sensörlerden elde edilen istatistiksel özniteliklerin korelasyon özniteliği kullanılarak NB ile %69,2 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile ortalama bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) ve L4 (yürüme) hareketleri için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

**Tablo 4.34.** Ardışık mutlak farklar öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>5</b>	4	0	0	0	0	1	0	0	0	0	0
L2	3	<b>6</b>	1	0	0	0	0	0	0	0	0	0
L3	1	1	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>9</b>	0	0	0	0	0	1	0	0
L5	0	0	0	0	<b>7</b>	0	0	1	0	1	1	0
L6	0	0	0	0	0	<b>10</b>	0	0	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	0	1	0	<b>9</b>	0	0	0	0
L9	0	0	0	0	0	0	0	1	<b>9</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>7</b>	3	0
L11	0	0	0	0	0	0	0	0	1	1	<b>8</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.35.** Ardışık Mutlak Farklar öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,500	0,036	0,556	0,500	0,526
L2	0,600	0,045	0,545	0,600	0,571
L3	0,800	0,009	0,889	0,800	0,842
L4	0,900	0,000	1,000	0,900	0,947
L5	0,700	0,000	1,000	0,700	0,824
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,009	0,909	1,000	0,952
L8	0,900	0,018	0,818	0,900	0,857
L9	0,900	0,009	0,900	0,900	0,900
L10	0,700	0,027	0,700	0,700	0,700
L11	0,800	0,036	0,667	0,800	0,727
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,817</b>	<b>0,017</b>	<b>0,824</b>	<b>0,817</b>	<b>0,817</b>

Sensörlerden elde edilen istatistiksel özniteliklerin ardışık mutlak farklar özniteliği kullanılarak NB ile %81,7 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile yüksek bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama), L6 (öne eğilme) ve L7 (kolları yukarı kaldırma) hareketleri için %100 başarı oranı gözlenmiştir. Diğer hareketler için ortalama başarı oranları gözlenmiştir.



**Tablo 4.36.** Medyan öznitelikleri için RF ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>7</b>	1	1	0	0	0	1	0	0	0	0	0
L2	2	<b>6</b>	2	0	0	0	0	0	0	0	0	0
L3	0	2	<b>8</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>5</b>	2	1	0	1	0	0	1	0
L5	0	0	0	3	<b>7</b>	0	0	0	0	0	0	0
L6	0	0	0	0	0	<b>7</b>	0	3	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	0	0	2	0	<b>6</b>	1	0	1	0
L9	1	0	0	0	0	0	0	0	<b>9</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>6</b>	4	0
L11	0	0	0	0	2	1	0	0	0	2	<b>5</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.37.** Medyan öznitelikleri için RF ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,700	0,027	0,700	0,700	0,700
L2	0,600	0,027	0,667	0,600	0,632
L3	0,800	0,027	0,727	0,800	0,762
L4	0,500	0,027	0,625	0,500	0,556
L5	0,700	0,036	0,636	0,700	0,667
L6	0,700	0,036	0,636	0,700	0,667
L7	1,000	0,009	0,909	1,000	0,952
L8	0,600	0,036	0,600	0,600	0,600
L9	0,900	0,009	0,900	0,900	0,900
L10	0,600	0,018	0,750	0,600	0,667
L11	0,500	0,055	0,455	0,500	0,476
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,717</b>	<b>0,026</b>	<b>0,717</b>	<b>0,717</b>	<b>0,715</b>

Sensörlerden elde edilen istatistiksel özniteliklerin medyan özniteliği kullanılarak RF ile %71,7 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile ortalama bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) ve L7 (kolları yukarı kaldırma) hareketleri için %100 başarı oranı gözlenmiştir. Diğer hareketler için ortalama başarı oranları gözlenmiştir.

**Tablo 4.38.** Çarpıklık öznitelikleri için RF ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>7</b>	1	1	0	0	0	0	0	1	0	0	0
L2	1	<b>7</b>	2	0	0	0	0	0	0	0	0	0
L3	0	3	<b>7</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>5</b>	2	0	1	1	0	0	1	0
L5	0	0	0	1	<b>8</b>	0	0	0	0	0	1	0
L6	0	0	0	0	0	<b>6</b>	1	3	0	0	0	0
L7	0	0	0	0	0	0	<b>10</b>	0	0	0	0	0
L8	0	0	0	1	0	3	0	<b>6</b>	0	0	0	0
L9	0	0	0	0	0	0	0	0	<b>10</b>	0	0	0
L10	0	0	0	0	0	0	0	0	0	<b>10</b>	0	0
L11	0	0	0	0	0	0	0	0	0	0	<b>10</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.39.** Çarpıklık öznitelikleri için RF ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,700	0,009	0,875	0,700	0,778
L2	0,700	0,036	0,636	0,700	0,667
L3	0,700	0,027	0,700	0,700	0,700
L4	0,500	0,018	0,714	0,500	0,588
L5	0,800	0,018	0,800	0,800	0,800
L6	0,600	0,027	0,667	0,600	0,632
L7	1,000	0,018	0,833	1,000	0,909
L8	0,600	0,036	0,600	0,600	0,600
L9	1,000	0,009	0,909	1,000	0,952
L10	1,000	0,000	1,000	1,000	1,000
L11	1,000	0,018	0,833	1,000	0,909
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,800</b>	<b>0,018</b>	<b>0,797</b>	<b>0,800</b>	<b>0,795</b>

Sensörlerden elde edilen istatistiksel özniteliklerin çarpıklık özniteliği kullanılarak RF ile %80 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile yüksek bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu yürüyüş) ve L11 (koşma) hareketleri için %100 başarı oranı gözlenmiştir. Diğer hareketler için ortalama başarı oranları gözlenmiştir.

**Tablo 4.40.** Basıklık öznitelikleri için Çok Katmanlı Algılayıcı ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>5</b>	2	2	0	0	0	0	0	1	0	0	0
L2	0	<b>6</b>	4	0	0	0	0	0	0	0	0	0
L3	1	6	<b>3</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>7</b>	1	0	0	0	0	1	1	0
L5	0	0	0	2	<b>4</b>	0	1	0	0	0	3	0
L6	0	0	0	0	0	<b>6</b>	1	3	0	0	0	0
L7	0	0	0	0	1	2	<b>7</b>	0	0	0	0	0
L8	0	0	0	0	0	2	0	<b>8</b>	0	0	0	0
L9	2	0	0	0	0	0	0	0	<b>8</b>	0	0	0
L10	0	0	0	1	0	0	0	0	0	<b>3</b>	6	0
L11	0	0	0	0	1	0	1	0	0	2	<b>6</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.41.** Basıklık öznitelikleri için Çok Katmanlı Algılayıcı ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,500	0,027	0,625	0,500	0,556
L2	0,600	0,073	0,429	0,600	0,500
L3	0,300	0,055	0,333	0,300	0,316
L4	0,700	0,027	0,700	0,700	0,700
L5	0,400	0,027	0,571	0,400	0,471
L6	0,600	0,036	0,600	0,600	0,600
L7	0,700	0,027	0,700	0,700	0,700
L8	0,800	0,027	0,727	0,800	0,762
L9	0,800	0,009	0,889	0,800	0,842
L10	0,300	0,027	0,500	0,300	0,375
L11	0,600	0,091	0,375	0,600	0,462
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,608</b>	<b>0,036</b>	<b>0,621</b>	<b>0,608</b>	<b>0,607</b>

Sensörlerden elde edilen istatistiksel özniteliklerin basıklık özniteliği kullanılarak Çok Katmanlı Algılayıcı ile %60,8 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile ortalama bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

**Tablo 4.42.** Minimum öznitelikleri için RF ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>4</b>	3	3	0	0	0	0	0	0	0	0	0
L2	4	<b>5</b>	1	0	0	0	0	0	0	0	0	0
L3	4	3	<b>3</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>6</b>	0	1	0	1	1	0	1	0
L5	0	0	0	0	<b>6</b>	2	0	0	1	0	1	0
L6	0	0	0	0	2	<b>3</b>	0	5	0	0	0	0
L7	0	0	0	0	0	0	<b>8</b>	0	0	2	0	0
L8	0	0	0	0	1	4	0	<b>4</b>	1	0	0	0
L9	0	0	0	1	0	0	0	0	<b>9</b>	0	0	0
L10	0	0	0	0	1	0	0	0	0	<b>6</b>	3	0
L11	0	0	0	1	0	1	0	0	0	2	<b>6</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.43.** Minimum öznitelikleri için RF ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,400	0,073	0,333	0,400	0,364
L2	0,500	0,055	0,455	0,500	0,476
L3	0,300	0,036	0,429	0,300	0,353
L4	0,600	0,018	0,750	0,600	0,667
L5	0,600	0,036	0,600	0,600	0,600
L6	0,300	0,073	0,273	0,300	0,286
L7	0,800	0,000	1,000	0,800	0,889
L8	0,400	0,055	0,400	0,400	0,400
L9	0,900	0,027	0,750	0,900	0,818
L10	0,600	0,036	0,600	0,600	0,600
L11	0,600	0,045	0,545	0,600	0,571
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,583	0,038	0,595	0,583	0,585

Sensörlerden elde edilen istatistiksel özniteliklerin minimum özniteliği kullanılarak RF ile %58,3 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile

düşük bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

**Tablo 4.44.** Maximum öznitelikleri için NB ile elde edilen karşılıklı matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>8</b>	1	0	0	0	0	0	0	1	0	0	0
L2	1	<b>6</b>	3	0	0	0	0	0	0	0	0	0
L3	1	3	<b>6</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>1</b>	4	0	0	2	0	2	1	0
L5	0	0	0	1	<b>6</b>	0	1	1	0	0	1	0
L6	0	0	0	0	0	<b>5</b>	1	3	0	0	1	0
L7	0	0	0	1	0	1	<b>8</b>	0	0	0	0	0
L8	0	0	0	0	1	4	0	<b>5</b>	0	0	0	0
L9	1	0	0	0	0	0	0	0	<b>9</b>	0	0	0
L10	0	0	0	0	0	0	1	0	0	<b>5</b>	4	0
L11	0	0	0	0	1	0	0	2	0	1	<b>6</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.45.** Maximum öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,800	0,027	0,727	0,800	0,762
L2	0,600	0,036	0,600	0,600	0,600
L3	0,600	0,027	0,667	0,600	0,632
L4	0,100	0,018	0,333	0,100	0,154
L5	0,600	0,055	0,500	0,600	0,545
L6	0,500	0,045	0,500	0,500	0,500
L7	0,800	0,027	0,727	0,800	0,762
L8	0,500	0,073	0,385	0,500	0,435
L9	0,900	0,009	0,900	0,900	0,900
L10	0,500	0,027	0,625	0,500	0,556
L11	0,600	0,064	0,462	0,600	0,522
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,625</b>	<b>0,034</b>	<b>0,619</b>	<b>0,625</b>	<b>0,614</b>

Sensörlerden elde edilen istatistiksel özniteliklerin maksimum özniteliği kullanılarak NB ile %62,5 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile

ortalama bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

**Tablo 4.46.** Varyasyon Katsayısı öznitelikleri için NB ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	<b>8</b>	0	0	0	0	0	1	0	1	0	0	0
L2	2	<b>4</b>	4	0	0	0	0	0	0	0	0	0
L3	1	4	<b>5</b>	0	0	0	0	0	0	0	0	0
L4	0	0	0	<b>4</b>	5	0	0	1	0	0	0	0
L5	0	0	0	4	<b>5</b>	1	0	0	0	0	0	0
L6	0	0	0	0	0	<b>5</b>	1	4	0	0	0	0
L7	0	0	0	0	0	1	<b>6</b>	2	0	0	1	0
L8	0	0	0	0	0	5	0	<b>5</b>	0	0	0	0
L9	1	2	0	0	0	0	0	0	<b>7</b>	0	0	0
L10	0	0	0	0	0	0	1	0	0	<b>7</b>	2	0
L11	0	0	0	0	0	0	1	0	0	2	<b>7</b>	0
L12	0	0	0	0	0	0	0	0	0	0	0	<b>10</b>

**Tablo 4.47.** Varyasyon Katsayısı öznitelikleri için NB ile elde edilen performanslar

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FP rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,800	0,036	0,667	0,800	0,727
L2	0,400	0,055	0,400	0,400	0,400
L3	0,500	0,036	0,556	0,500	0,526
L4	0,400	0,036	0,500	0,400	0,444
L5	0,500	0,045	0,500	0,500	0,500
L6	0,500	0,064	0,417	0,500	0,455
L7	0,600	0,036	0,600	0,600	0,600
L8	0,500	0,064	0,417	0,500	0,455
L9	0,700	0,009	0,875	0,700	0,778
L10	0,700	0,018	0,778	0,700	0,737
L11	0,700	0,027	0,700	0,700	0,700
L12	1,000	0,000	1,000	1,000	1,000
<b>Ortalama</b>	<b>0,608</b>	<b>0,036</b>	<b>0,617</b>	<b>0,608</b>	<b>0,610</b>

Sensörlerden elde edilen istatistiksel özniteliklerin varyasyon katsayısı özniteliği kullanılarak NB ile %60,8 başarı oranı gözlenmiştir. Tek bir istatistiksel özellik ile ortalama bir başarı oranı elde edilmiştir. L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Diğer hareketler için çok düşük başarı oranları gözlenmiştir.

Tüm özelliklerin ayrı ayrı başarı oranı Tablo 4.48’de özetlenmiştir. Tabloya bakıldığında en etkili özelliğin ardışık mutlak farklar özneliğinin olduğu görülmektedir. Daha sonra sırayla en önemli öznelikler çarpıklık, entropi oldukları görülmektedir.

**Tablo 4.48.** Özelliklere göre başarı oranları

Özellikler	Sınıflandırma Yöntemi	Başarı Oranı
Ortalama	Naive Bayes	%66,66
Standart Sapma	Naive Bayes	%52,50
Enerji	Naive Bayes	%51,66
Entropi	Naive Bayes	%78,33
Korelasyon	Naive Bayes	%69,16
Ardışık Mutlak Farklar	Naive Bayes	%81,66
Medyan	Random Forest	%71,66
Çarpıklık	Random Forest	%80,00
Basıklık	Çok Katmanlı Algılayıcı	%60,83
Minimum	Random Forest	%58,33
Maximum	Naive Bayes	%62,50
Varyasyon Katsayısı	Naive Bayes	%60,83

## 5. TARTIŞMA

HT, kişilerin gösterdikleri davranışları hareketleri birbirinden ayırma işlemidir. Giyilebilir sensörleri kullanarak HT, rehabilitasyon uzmanlarına hasta hareketliliği hakkında değerli bilgiler verme potansiyeline sahip büyümekte olan bir alandır ve insan hareketlerinin izlenmesi ve tanınması, özellikle yaşlılar ve engellilerin ve kronik hastalıkları olan hastaların zaman içindeki fiziksel ve davranışsal profillerindeki değişimleri değerlendirmek için önemli olmaktadır. İnsan HT araştırma alanı; sağlık, ofis senaryoları, eğitim, robotik, sanayi sektörü (Maurtua ve ark., 2007), akıllı evler, eğlence sektörü (Kunze ve ark., 2006; Minnen ve ark., 2006; Ladha ve ark., 2013) gibi birçok sektörde birçok yenilikçi uygulama ile son yıllarda hızla genişlemiştir (Bao ve Intille, 2004; Tapia ve ark., 2004; Ravi ve ark., 2005; Logan ve ark., 2007). HT, insan aktivitelerini sınıflandırmak için sensör verilerini yorumlama süreci olarak tanımlanabilir. HT sistemleri, kişinin vücuduna bağlı heterojen sensörleri kullanarak ve insan eylemlerinin durumunu yansıtan sayısız fizyolojik sinyallerin sürekli izlenmesini sağlayarak kullanıcının ve çevresinin durumunu yakalamayı hedeflemektedir. Literatürde birçok HT yaklaşımı mevcuttur ve her araştırma grubu belirli bir veri örneği, tanımlanmış sınıflar, algoritma ve öznelik kümesi sunmaktadır. Bu nedenle HT algoritmasının geliştirilmesine rehberlik etmek için anlamlı bilgilerin çıkarılması zordur.

Sensör teknolojisindeki gelişmeler, artık uzun vadeli kayıtlar, bilgi işlem ve hareket halindeyken sürekli etkileşim için uygun form faktörlerine ve pil ömrüne izin vermektedir. Fakat giyilebilir sensörlerle hareket tanımda problem oluşturan sorunlardan biri ise EEG, ivmeölçer, cayo ve manyometre sinyallerinin gürültü ve ortam şartlarından etkilenmeleriyle sinyallerin kalitesini değiştirmesidir. Bu çalışma; yeni ve daha iyi sensörler tasarlamayı amaçlayan bakış açısı ile ilgilenmemektedir. Bunun yerine, mevcut sensörlerden ölçümler yapmak ve insan vücudunun hareketinin mümkün olan en iyi karakterizasyonunu oluşturmak için özellik elde etme yöntemlerini araştırmaktadır.

Bu çalışmada, vücuttaki sensörlerden insan fiziksel aktivitelerin belli başlı olanaklarının sınıflandırılması için bir insan hareketi tanıma yöntemi uygulamak için gerekli aşamalar gözden geçirilmiştir. Bu çalışmanın en önemli bir katkısı, özellik boyut azaltımı için hareket tanıma literatüründe olmayan yeni bir yöntem önerilmesidir. Öznelik çıkarma; hareket tanıma sürecinde önemli bir rol oynamaktadır, çünkü



öznitelikler iyi seçilmediyse, sınıflandırma performansı düşecektir. 1B-YİÖ denilen bu yaklaşım ile sensör sinyallerden istatistiksel özellikler elde edilerek Random Committee, Random Forest, Naive Bayes gibi farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Önerilen yöntemi test etmek için UCI veri tabanında paylaşılan Mhealth veri seti kullanılmıştır. Çeşitli sensörlerden alınan sinyal değerleri 10 gönüllüden alınmış olan belirli hareketler esnasında sensörlerin kaydettiği değerlerden oluşmaktadır. Toplamda 12 hareketin (hareketsiz durma, oturma ve rahatlama, uzanma, yürüme, merdiven tırmanma, öne eğilme, kolların yukarı doğru kaldırılması, dizlerin bükülmesi (çömelme), bisiklet sürme, tempolu yürüyüş, koşma, ön ve arkaya zıplama) tanınması amaçlanmıştır. Yapılan kapsamlı test sonuçlarına göre %92,5 oranında (Random Committee) sınıflandırma doğruluğu gerçekleştirilmiştir. Her üç sınıflandırmada da UCI veri kümesindeki L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (ön ve arkaya zıplama) hareketlerindeki %100 sınıflandırma önerilen yaklaşımın avantajlarını ortaya koymaktadır. En başarılı sınıflandırmayı gerçekleştiren (%92,5) Random Committee sınıflandırma yöntemiyle gerçekleştirilen test sonuçlarına göre L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (ön ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. Her üç sınıflandırma yönteminde de ayırt etmede zorluk yaşanan hareket L2 (oturma ve rahatlama) dır. Çünkü bu hareket L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetildiği için ayırt edilememiştir.

MHealth veri kümesi elde edilirken kişilerin göğüs bölgesine, sağ ele ve sol bacağı çeşitli sensörler yerleştirilmiştir. Bunlar; cayro, ivme sensörü ve manyometredir. Ayrıca beyin dalgalarındaki hareketlilikleri de gözetmek için kişilerin EEG sinyallerinin kaydı da tutulmuştur. Bu çalışmada aynı zamanda hangi sensör türünün veri kümesindeki hangi hareketleri sınıflandırırken daha etkili olduğu da aynı zamanda tespit edilmeye çalışılmıştır. Yalnızca ivme sensörlerinden elde edilen öznitelikler ile %85,8 (Random Committee) başarı ile veri kümesindeki hareketler sınıflandırılmıştır. L1 (hareketsiz durma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (ön ve arkaya zıplama) hareketleri için kesin doğrulukla sınıflandırma başarısı göstermiştir. Yalnızca cayro sensörlerden elde edilen öznitelikler ile gerçekleştirilen sınıflandırmaya göre de %87,5 (Random Committee) doğruluk başarısı gerçekleştirilmiştir. L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu

yürüyüş yapma) ve L12 (ön ve arkaya zıplama) hareketleri kesin doğrulukla ayırt edilebilmiştir. Yalnızca manyometre sensörlerden elde edilen öznitelikler ile sınıflandırma gerçekleştirildiğinde %89,2 (Random Committee) doğruluk başarıları gerçekleştirilmiştir ve L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (çömelme), L9 (bisiklet sürme), ve L12 (ön ve arkaya zıplama) hareketleri için kesin doğrulukla ayırtma gerçekleştirilmiştir. Yalnızca EEG sinyallerinden elde edilen öznitelikler ile gerçekleştirilen sınıflandırmada %89,2 başarı gerçekleştirilmiştir ve yalnızca EEG sinyalleri kullanılarak L4 (yürüme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), ve L12 (ön ve arkaya zıplama) hareketleri kesin doğruluklarla sınıflandırılabilmiştir. Her dört sensör de veri kümesini iyi ayırt edebilmek için tek başlarına gösterdikleri doğruluklara bakacak olursak gerekli olan sensörlerdirler. Fakat her üç çeşit sensör ve EEG sinyalleri L2 (oturma ve rahatlama) hareketini ayırt etmede zorlanmıştır, hepsi de bu hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetmiştir. İvme sensörü ve manyometrenin yine de L2 (oturma ve rahatlama) hareketini diğerlerine oranla ayırt etmede biraz daha iyi olduğu söylenebilir. Bu hareketi en başarısız sınıflandıran ise EEG sinyalleridir.

Kullanılan her üç sensörün (ivme, cayo, manyometre) X, Y, Z eksenlerinden elde edilen öznitelikler ile sınıflandırma analizi de gerçekleştirilmiştir. X ekseninden elde edilen öznitelikler ile toplamda %92,5 (RC), Y ekseninden elde edilen öznitelikler ile toplamda %90 (RC), Z ekseninden elde edilen öznitelikler ile %87,5 (RC) oranında başarılı sınıflandırma gerçekleştirilmiştir. X ekseninden L1 (hareketsiz durma), L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu yürüyüş), L11(koşma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. Y ekseninden L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. Z ekseninden L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) hareketleri için %100 sınıflandırma oranı bulunmuştur. L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. Özet olarak X ekseninin veri kümesindeki hareketleri sınıflandırmada daha başarılı olduğu görülmüştür.

Bu çalışmada sensörlerden elde edilen istatistiksel özniteliklerin her birinin veri kümesindeki aktiviteleri sınıflandırmadaki etkisi de araştırılmıştır. Elde edilen özniteliklerden ortalama, standart sapma, enerji, basıklık, minimum, maximum ve varyasyon ile; L12 (öne arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. Entropi ile L12 (öne arkaya zıplama) ve L6 (öne eğilme), korelasyon ile; L12 (öne arkaya zıplama) ve L4 (yürüme), ardışık mutlak farklar ile; L12 (öne arkaya zıplama), L6 (öne eğilme) ve L7 (kolları yukarı kaldırma), medyan ile; L12 (öne arkaya zıplama) ve L7 (kolları yukarı kaldırma), çarpıklık ile; L12 (öne arkaya zıplama), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu yürüyüş) ve L11 (koşma) hareketleri için %100 başarı oranı gözlenmiştir. Genel olarak sınıflandırmayı etkileyen en önemli özelliğin ardışık mutlak farklar olduğu görülmüştür ve sırasıyla önem düzeyine göre sıralamak gerekirse çarpıklık, entropi, medyan, korelasyon, ortalama, maximum, varyasyon katsayısı, basıklık, minimum, standart sapma ve enerji olduğu görülmektedir.

## 6. KAYNAKLAR

- Akgün S., Bakar C., Budakoğlu İ., 2004. Dünyada ve Türkiye’de yaşlı nüfus eğilimi, sorunları ve iyileşme önerileri, *Türk Geriatri Dergisi*, vol. 7, 105-110.
- Al Jeroudi M. A., Latief M., Akmeliawati R., 2015. Online Sequential Extreme Learning Machine Algorithm Based Human Activity Recognition Using Inertial Data, *10th Asian Control Conference (ASCC)*, Kota Kinabalu, Malaysia, 1-6.
- Alnihoud J., 2012. Content-Based Image Retrieval System Based on Self Organizing Map, Fuzzy Color Histogram and Subtractive Fuzzy Clustering, *International Arab Journal of Information Technology*, vol. 9, no. 5, 452-458.
- Atallah L., Lo B., King R., Yang G. Z., 2011. Sensor positioning for activity recognition using wearable accelerometers, *IEEE Transactions on Biomedical Circuits and Systems*, 320-329.
- Avcı A., Bosch S., Marin-Perianu M., Marin-Perianu R., Havinga P., 2010. Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications: A Survey, *In Proceedings of the 23rd International Conference on Architecture of Computing Systems (ARCS)*, Hannover, Germany, 1-10.
- Bachmann E., Yun X., McKinney D., McGhee R., Zyda M., 2003. Design and Implementation of MARG Sensors for 3-DOF Orientation Measurement of Rigid Bbodies, *IEEE, International Conference on Robotics and Automation PCRA 2003*, Taipei, Taiwan, 1171-1178.
- Banos O., Villalonga C., Garcia R., Saez A., Damas M., Holgado, J. A., Lee S., Pomares H., Rojas I., 2015. Implementation and validation of a novel open framework for agile development of mobile health applications, *BioMedical Engineering OnLine*, vol. 14, no. S2:S6, 1-20.
- Bao L., Intille S., 2004. Activity recognition from user-annotated acceleration data, *In Proceedings of Pervasive*, 1-17.
- Bayat A., Pomplun M., Tran D. A., 2014. A study on human activity recognition using accelerometer data from smartphones, *Procedia Computer Science*, 450-457.
- Capela N. A., Lemaire E. D., Baddour N., 2015. Feature Selection for Wearable Smartphone-Based Human Activity Recognition with Able bodied, Elderly, and Stroke Patients. *Lovis C, ed. PLoS ONE.*, 4-10.
- Chatlani N., Soraghan J. J., 2010. Local binary patterns for 1-D signal processing, *Proceedings of the 18th European Signal Processing Conference (EUSIPCO '10)*, Aalborg, Denmark, 95-99.
- Chatlani N., Soraghan J. J., Zhu Q., 2012. 1-D Local binary patterns based VAD used INHMM-based improved speech recognition, *20th European Signal Processing Conference (EUSIPCO '12)*, Bucharest, Romania, 1633-1637.
- Chernbumroong S., Can S., Atkin A., Yu H., 2013. Elderly activities recognition and classification for applications in assisted living, *Expert Systems with Applications*, no. 5, 1662-1674.
- Çimen E., 2013. Çok Yüzlü Konik Fonksiyonlar Temelli Sınıflandırma Yaklaşımları ile Hareket Tanıma, yüksek lisans, *Anadolu üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir, 18-25.

- Damaševičius R., Vasiljevas M., Šalkevičius J., Woźniak M., 2016. Human Activity Recognition in AAL Environments Using Random Projections, *Computational and Mathematical Methods in Medicine*, 1-17.
- Dardas N. H., Georganas N. D., 2011. Real-Time hand gesture detection and recognition using bag-of-features and support vector machine techniques, *IEEE Transactions on Instrumentation and Measurement*, vol. 60, no.11, 3592-3607.
- Elvira V., Naazabal-Renteria A., Artes-Rodrigues A., 2014. A novel feature extraction technique for human activity recognition, *Statistical Signal Processing (SSP), IEEE*, Gold Coast, VIC, Australia, 177-180.
- Ertuğrul Ö. F., Kaya Y. ve Tekin R., 2015. A novel approach for SEMG signal classification with adaptive local binary patterns, *Medical&biological engineering & computing*, vol. 54, no. 7, 1137-1146.
- Feng X., Pietikäinen M., Hadid A., 2005. Facial Expression Recognition with Local Binary Patterns and Linear Programming, *MICAI 2005: Advances in Artificial Intelligence*, 328-336.
- Foerster F., Fahrenberg J., 2000. Motion pattern and posture: Correctly assessed by calibrated accelerometers, Behavior Research Methods, *Instruments&Computers*, vol. 32, no. 3, 450-457.
- Gunay A., Nabyev V. V., 2008. Automatic age classification with LBP, *23rd International Symposium on Computer and Information Sciences ISCIS*, Istanbul, 1-4.
- Howcroft J., Kofman J., Lemaire E. D., 2017. Feature selection for elderly faller classification based on wearable sensors, *Journal of NeuroEngineering and Rehabilitation*, vol. 14, 47.
- Kaya Y., Uyar M., Tekin R., Yıldırım S., 2014. 1D-local binary pattern based feature extraction for classification of epileptic EEG signals, *Applied Mathematics and Computation*, vol. 243, 209-219.
- Kaya Y., Ertuğrul Ö. F., 2015. Doküman dili tanıma için yeni bir öznelik çıkarım yaklaşımı: İkili Desenler, *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 31, no. 4, 1085-1094.
- Kunze K., Barry M., Heinz, E. A., Lukowicz P., Majoe D., Gutknecht J., 2006. Towards recognizing taichi, An initial experiment using wearable sensors, *Proceedings of FAWC (2006)*, 1-6.
- Kurban O. C., 2014, İnsan aktivitelerinin giyilebilir sensörler ile özellik çıkarımı yapmadan sınıflandırılması, Yüksek lisans, *Yıldız Teknik Üniversitesi Fen bilimleri enstitüsü*, İstanbul, 8-19.
- Ladha C., Hammerla N., Olivier P., Thomas P., 2013. ClimbAX: Skill assessment for climbing enthusiasts, *Int. Conf. Ubiquitous Comp. (UbiComp)*, 8-12.
- Lara O. D., Labrador M. A., 2012. A survey on human activity recognition using wearable sensors, *IEEE Communications Surveys & Tutorials*, vol. 15, no. 3, 1192-1209.
- Logan B., Healey J., Philipose M., Tapia E. M., Intille S., 2007. A long-term evaluation of sensing modalities for activity recognition. *In Proceedings of UbiComp. Springer-Verlag*, 483-500.

- Maaenpaaa T., Pietikaainen M., 2004. Texture Analysis with Local Binary Patterns, *IEEE Trans. Pattern Analysis Machine Intelligence*, vol. 28, no. 12, 2037-2041.
- Maurtua P. T., Kirisci T., Stiefmeier M. L., Sbodio H. W., 2007. A wearable computing prototype for supporting training activities in automotive production, *4th International Forum on Applied Wearable Computing*, 1-12.
- Mantjarvi J., Himberg J., Seppanen T., 2001. Recognizing human motion with multiple acceleration sensors, *IEEE International Conference on Systems, Man, and Cybernetics*, 747-52.
- Maurer U., Smailagic A., Siewiorek D. P., Deisher M., 2006. Activity recognition and monitoring using multiple sensors on different body positions, *International Workshop on Wearable and Implantable Body Sensor Networks (BSN '06)*, IEEE, Cambridge, Mass, USA, 113-116.
- McCool P., Chatlani N., Petropoulakis L., Soraghan J. J., Menon R. ve Lakany H., 2014. Lower arm electromyography (EMG) activity detection using local binary patterns, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 22, 1003-12.
- Minnen D., Starner T., Essa I., Isbell C., 2006. Discovering characteristic sections from on-body sensor data, *In Proceedings of the 10th IEEE International Symposium on Wearable Computers (ISWC)*, 142-158.
- Nabiyev V. V., Kurt B., 2007. Facial Expression Recognition, *II. Uluslararası Bilim ve eğitimde Bilgi ve İletişim Teknolojileri Uygulamaları Konferansı*, Bakü, Azerbaycan, 779-791.
- Nabiyev V. V., Kurt B., 2011. Down Syndrome Recognition Using Local Binary Patterns And Statistical Evaluation Of The System, *Expert Systems with Applications*, vol. 38, 8690-8695.
- Ojala T., Pietikinen M., Harwood D., 1996. A comparative study of texture measures with classification based on featured distribution, *Pattern Recognition*, 51-59.
- Ojala T., Pietikinen M., 2000. Gray scale and rotation invariant texture classification with local binary patterns, *Computer Vision, ECCV Proceedings, Lecture Notes in Computer Science, Springer*, 404-420.
- Ojala T., Pietikäinen M., 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Trans. Pattern Anal. Mach. Intell.*, 971-987.
- Ogris G., Stiefmeier T., Lukowicz P., Tröster, G., 2008. Using a complex multi-modal on-body sensor system for activity spotting, *ISWC*, 55-62.
- Orjuela S. A., Yañez J. P., Philips W., 2014. Local Binary Patterns: New Variants and New Applications. *Studies in Computational Intelligence Springer Heidelberg*, vol. 506, 85-112.
- Parkka J., Ermes M., Korpipaa P., Mantjarvi J., Peltola J., Korhonen I., 2006. Activity classification using realistic data from wearable sensors, *IEEE Transactions Pattern Anal. Mac.*, vol. 4, no. 4, 403-413.
- Ponce H., Martinez M. L., Miralles P. L., 2016. A Novel Wearable Sensor-Based Human Activity Recognition Approach Using Artificial Hydrocarbon Networks, *Sensors (Basel)*, vol. 16, no. 7, 1033.

- Rashidi P., Cook D. J., 2009. The resident in the loop: Adapting the smart home to the user, *IEEE Trans. Syst. Man. Cybern. J. Part A*, 39, 949-959.
- Ravi N., Dandekar N., Mysore P., Littman M. L., 2005. Activity recognition from accelerometer data, *In Proceedings of the 17th International Conference on Innovative Applications of Artificial Intelligence*, 1541-1546.
- Selvarajah S., Kodituwakku S., 2011. Analysis and Comparison of Texture Features for Content Based Image Retrieval, *International Journal of Latest Trends in Computing*, vol. 2, no. 1, 108-113.
- Sergy'an S., 2008. Color Histogram Features Based Image Classification in Content-Based Image Retrieval Systems, *6th International Symposium on Applied Machine Intelligence and Informatics*, Herlany, 22-224.
- Shannon C. E., 1948. A Mathematical Theory of Communication, *The Bell System Technical Journal*, vol. 27, 623-656.
- Sung J., Ponce C., Selman B., Saxena A., 2011. Human activity detection from RGBD images, *In Proceedings of the AAAI Workshop on Plan, Activity, and Intent Recognition*, vol: 32 no. 8, 951-970.
- Tapia E. M., Intille S. S., Larson K., 2004. Activity recognition in the home using simple and ubiquitous sensors, *In Proceedings of Pervasive*, 158-175.
- Tunçel O., Altun K., Barshan B., 2009. Jiroskop Sinyallerinin İşlenmesiyle Bacak Hareketlerinin Sınıflandırılması, *IEEE 17th Conference on Signal Processing, Communications, and Applications (SIU 2009)*, Antalya, Turkey, 349-352.
- Tural K., Akdoğan E., 2017. Akıllı telefonların algılayıcılarının verilerini kullanarak Yapay Sinir Ağları ile İnsan Hareketlerinin Sınıflandırılması, *Türkiye Otomatik Kontrol Ulusal Toplantısı-TOK 2017*, 479-483.
- Wang X., Rosenblum D., Wang Y., 2012. Context-aware mobile music recommendation for daily activities, *In: Proceedings of the ACM International Conference on Multimedia*, NewYork, USA, 99-108.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

Bahar Yavuz  
Siirt-Kurtalan 25.02.1989  
baharyavuzz@gmail.com

### EĞİTİM

Lise	Siirt Lisesi Yabancı Dil Ağırlıklı Bölüm	2006
Üniversite	Fırat Üniversitesi, Bilgisayar Mühendisliği	2014
Yüksek Lisans	Siirt Üniversitesi, Elektrik-Elektronik ABD	2018

### BİLİMSEL ÇALIŞMALAR

- YAVUZ BAHAR, KAYA YILMAZ, Hareket Tanıma İçin Yeni Bir Öznitelik Çıkarım Yöntemi (2017), IATS'17 8th INTERNATIONAL ADVANCED TECHNOLOGIES SYMPOSIUM (Tam Metin Bildiri/Sözlü Sunum)