



## New approaches based on local binary patterns for gender identification from sensor signals

Fatma Kuncan<sup>1</sup> , Yılmaz Kaya<sup>1</sup> , Melih Kuncan<sup>2</sup>

<sup>1</sup>Department of Computer Engineering, Siirt University, Siirt, 56100, Turkey

<sup>2</sup>Department of Electrical - Electronic Engineering, Siirt University, Siirt, 56100, Turkey

### Highlights:

- Three different approaches based on 1D-LBP were proposed for GI
- The proposed methods are sensitive to new approach to noise
- High success rates were observed with the proposed approaches

### Graphical/Tabular Abstract

Gender identification (GI) is to determine the sex of the individual based on the characteristics that distinguish between male and female. In this study, three different feature extraction methods are proposed for gender identification by using signals obtained from accelerometers, magnetometers and gyroscope sensors installed in 5 different body parts of the individuals. 96.04%, 96.72% and 97.28% success rates were perceived with the recommended methods, respectively. In the study, attributes, motions, sensor port, sensor type that affect GI success were determined. The achievements of the proposed methods have been found to be more successful than the feature groups provided by the frequency and time domains of the proposed feature extraction methods, which are also compared with the success of the attribute groups derived from the same sensor signals from the time and frequency domains.

### Keywords:

- Gender identification
- Sensor signals
- 1D-LBP
- 1D-RLBP
- W-1D-RLBP
- Feature extraction




Figure A. Gender identification system

### Article Info:

Research Article  
Received: 23.05.2018  
Accepted: 05.01.2019

### DOI:

10.17341/gazimmfd.426259

### Acknowledgement:

This work was supported by Scientific Research Projects Coordination Unit of Siirt University as a project with the number 2018-SIUFEB-DR-009.

### Correspondence:

Author: Melih Kuncan  
e-mail:  
melihkuncan@siirt.edu.tr  
phone: +90 484 212 1111 /  
3033

### Purpose:

In this study, three different feature extraction methods are proposed for gender identification as seen in the Fig. A.

### Theory and Methods:

Feature extraction from signals is one of the most critical stages of GI. Because the success of GI depends on the attributes, different transformation methods have been applied to the signals obtained from sensors such as One Dimensional Local Binary Patterns (1D-LBPs), One Dimensional Robust Local Binary Patterns (1D-RLBPs) and Weighted One-Dimensional Robust Local Binary Patterns (W-1D-RLBPs). By using these attributes, different machine learning methods (SVM, RF, ANN, Knn) were elaborated for classification.

### Results:

The features obtained by the proposed approaches are classified by different machine learning methods. The most successful classification method was observed as Knn. The success rates of 94.04%, 96.72% and 97.28% were observed with the recommended approaches. The W-1D-RLBP method was found to provide more effective attributes for GI than the other two methods.

12 different statistical features were calculated from the sensor signals. A high success rate of 97.06% was observed with the only entropy features in the trials to determine which feature was effective.

In addition, grading was performed for each sensor type to determine the effect of accelerometers, gyroscopes and magnetometers on GI. The success rates were 91.33%, 89.21% and 89.43% respectively. It was found more appropriate to use these three types of sensors together.

### Conclusion:

In all trials, the W-1D-RLBP approach was found to be more successful than the other 1D-LBP and 1D-RLBP approaches. As a result, it has been found that the proposed feature inference approaches provide effective attributes for GI. It is also considered that the proposed approaches can be applied to different signals.



## Sensör işaretlerinden cinsiyet tanıma için yerel ikili örüntüler tabanlı yeni yaklaşımlar

Fatma Kuncan<sup>1</sup>, Yılmaz Kaya<sup>1</sup>, Melih Kuncan<sup>2\*</sup>

Siirt Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Siirt, 56100, Türkiye

### Ö N E Ç İ K A N L A R

- CT için YİÖ tabanlı üç farklı yaklaşım önerilmiştir.
- Önerilen yöntemler gürültüye duyarlı yeni sağlam yaklaşımlardır.
- Önerilen yaklaşımlar ile yüksek başarı oranları gözlenmiştir

#### Makale Bilgileri

Araştırma Makalesi  
Geliş: 23.05.2018  
Kabul: 05.01.2019

#### DOI:

10.17341/gazimmfd.426259

#### Anahtar Kelimeler:

Cinsiyet tanıma, sensör işaretleri, bir boyutlu yerel ikili örüntüler, bir boyutlu sağlam yerel ikili örüntüler, ağırlıklandırılmış bir boyutlu sağlam yerel ikili örüntüler, öznelik çıkarımı

#### ÖZET

Cinsiyet tanıma (CT) erkek ve kadın arasında ayırım yapan özelliklere dayalı olarak bireyin cinsiyetini belirlemektir. Bu çalışmada kişilerin 5 farklı bölgesine takılmış olan ivmeölçer, manyetometre ve jiroskop sensörlerinden elde edilen işaretler kullanılarak cinsiyet tanıma (CT) için üç (3) farklı öznelik çıkarım metodu önerilmiştir. İşaretlerden öznelik çıkarımı CT'nin en önemli aşamalarından biridir. Çünkü CT'nin başarısı çıkarılan özneliklere bağlıdır. Sensörlerden elde edilen işaretlere Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ), Bir Boyutlu Sağlam Yerel İkili Örüntüler (1B-SYİÖ) ve Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-SYİÖ) olmak üzere farklı dönüşüm yöntemleri uygulanmıştır. Dönüşüm işlemlerinden sonra yeni oluşan işaretlerden istatistiksel öznelikler elde edilmiştir. Bu öznelikler kullanılarak farklı makine öğrenmesi yöntemler (SVM, RF, YSA, Knn) ile sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen sonuçlara göre 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ yöntemlerin CT için etkin öznelikler sağladığı görülmüştür. Önerilen yöntemlerle sırası ile %96,04, %96,72 ve %97,28 başarı oranları gözlenmiştir. Çalışmada ayrıca CT başarısını etkileyen öznelikler, hareketler, sensör bağlantı noktası, sensör türü belirlenmiştir. Önerilen yöntemlerin başarıları aynı sensör işaretlerinden zaman ve frekans düzleminden elde edilen öznelik grupların başarıları ile de karşılaştırılmış önerilen öznelik çıkarım yöntemlerinin CT'da frekans ve zaman düzleminin sağladığı öznelik gruplarına göre çok daha başarılı bulunmuştur.

## New approaches based on local binary patterns for gender identification from sensor signals

### H I G H L I G H T S

- Three different approaches based on 1D-LBP were proposed for GI
- The proposed methods are sensitive to new approach to noise
- High success rates were observed with the proposed approaches

#### Article Info

Research Article  
Received: 23.05.2018  
Accepted: 05.01.2019

#### DOI:

10.17341/gazimmfd.426259

#### Keywords:

Gender identification, sensor signals, one dimensional local binary patterns, one dimensional robust local binary patterns, weighted one-dimensional robust local binary Patterns, feature extraction

#### ABSTRACT

Gender identification (GI) is to determine the sex of the individual based on the characteristics that distinguish between male and female. In this study, three different feature extraction methods are proposed for gender identification by using signals obtained from accelerometers, magnetometers and gyroscope sensors installed in 5 different body parts of the individuals. Feature extraction from signals is one of the most critical stages of GI. Because the success of GI depends on the features, different transformation methods have been applied to the signals obtained from sensors such as One Dimensional Local Binary Patterns (1D-LBPs), One Dimensional Robust Local Binary Patterns (1D-RLBPs) and Weighted One-Dimensional Robust Local Binary Patterns (W-1D-RLBPs). By using these features, different machine learning methods (SVM, RF, ANN, Knn) were elaborated for classification. According to the results, it was seen that 1D-LBPs, 1D-RLBPs and W-1D-RLBPs methods provided useful features for GI. 96.04%, 96.72% and 97.28% success rates were perceived with the proposed methods, respectively. In the study, features, motions, sensor port, sensor type that affect GI success were determined. The achievements of the proposed methods have been found to be more successful than the feature groups provided by the frequency and time domains of the proposed feature extraction methods, which are also compared with the success of the feature groups derived from the same sensor signals from the time and frequency domains.

## 1. GİRİŞ (INTRODUCTION)

Otomatik cinsiyet tanıma (CT) giderek artan bir çalışma konusu haline gelmiştir; çünkü cinsiyet, erkek ve kadın sosyal aktiviteleri ile ilgili önemli bilgiler taşımaktadır. Genellikle, yeni bir insanla tanışıldığı zaman bireyler tarafından ilk dikkat edilen şey büyük olasılıkla karşısındaki kişinin cinsiyetidir. Bir insan bu kararı çok kolayca vermesine karşın aynı iş bilgisayar sistemleri (metin, ses, görüntü uygulamaları vb.) için zorlu bir görevdir [1]. Cinsiyet sınıflandırmanın amacı, erkeklik ve kadınlık arasında ayırım yapan özelliklere dayalı olarak bireyin cinsiyetini tanımadır. Sosyal medyanın ve akıllı cihazların gelişmesiyle birlikte CT'nin içinde bulunduğu uygulamalar gün geçtikçe önem kazanmıştır. CT, gözetim sistemlerinin becerisini artırmak, mağaza yöneticilerinin müşterileri analiz etmesi, güvenlik sistemleri uygulamalarında, biyometride, takip sistemlerinde, insan-bilgisayar etkileşimi uygulamalarında, robotların veya bir sistemin cinsiyet algılamasını sağlamak vb. birçok uygulamada fayda sağlamaktadır [1-2]. Ayrıca, cinsiyet bilgisi sağlık hizmetlerinin, akıllı alanların ve biyometrik tabanlı erişim kontrol uygulamalarının parçası olan uzman ve akıllı sistemler tarafından da kullanılabilir [2].

CT, bilgisayar biliminde önemli bir araştırma konusu olarak kendisine yer bulmuştur. Otomatik CT, yüz [3], ses [4] veya yürüyüş [5] vb. özellikler kullanılarak tespit edilebileceği yapılan araştırmalarda görülmüştür. CT çalışmalarının büyük bir çoğunluğunun görüntü (resim) üzerinde olduğu görülmektedir [6]. Gutta ve ark., FERET yüz veri tabanı için poz özniteliklerini kullanarak CT gerçekleştirmişlerdir [7]. Moghaddam vd. ise doğrusal olmayan Destek Vektör Makineleri (DVM) aracılığıyla, yine FERET yüz veri tabanından imgelerin düşük çözünürlüklü hallerini kullanarak görüntüye dayalı CT sistemi gerçekleştirmişlerdir [8]. Li vd. çalışmalarında ise uzamsal Gauss karışım modelleri (SGMM) kullanılmıştır [9]. SGMM, klasik Gauss karışım modellerinin (GMM) sahip olduğu tam görüntü açıklayıcılığıyla birlikte imgelerin yanlış hizalanmasına karşı dayanıklılık gibi avantajlara sahip olduğuna değinmişlerdir. Chen vd. CT için kızılötesi ve termal yüz görüntüleri kullanmışlardır [10]. Yazarlar, yerel ikili örüntüler histogram özniteliklerini kullanarak SVM, Knn, Adaboost gibi farklı sınıflandırma yöntemleri ile CT işlemini gerçekleştirmişlerdir. Bir diğer çalışmada Danisman vd. saç hacmi, bıyık ve yüz şekli bilgileri kullanan bulanık çıkarım temelli CT yaklaşımı önermişlerdir [12]. Kişinin yürüyüşü de CT için önemli bilgiler içermektedir. Literatürde yürüyüş görüntülerini kullanarak CT gerçekleştirilen çalışmalar da bulunmaktadır [13-15].

Araştırmacılar ayrıca kulak [16], parmak izi [17], el geometrisi [18] ve iris [19] gibi farklı uzuvlar için de CT için çalışmalar yapmışlardır. Li vd. CT için yüz ve parmak izi füzyonu kullanmışlardır [20]. Bazı yazarlar, biyometride kullanıcı kimlik doğrulama başarısının, cinsiyet bilgisini geleneksel biyometrik özelliklerle entegre ederek

artırılabilirliğini belirtmişlerdir [21-24]. Jain vd. yüz ve parmak izi öznitelikleri ile birlikte boy ve etnik köken gibi hassas biyometrik öznitelikler kullanarak daha iyi bir kimlik doğrulama performansı elde edildiğini belirtmişlerdir [24].

Son yıllarda akıllı telefonların kullanımı hızla artmıştır. Akıllı telefonlar, günlük hayatımızda önemli bir rol oynamaktadır. Bu nedenle, akıllı telefon tabanlı birçok çalışmanın olduğu görülmektedir. Thang vd. çalışmalarında kullanıcı kimlik doğrulaması için akıllı telefonun ivmeölçer sensörü kullanılırken [25], Zhong vd. çalışmasında ise akıllı telefonun hem ivmeölçer hem de jiroskop sensörleri kullanılmıştır [26]. Giyilebilir sensör bilgileri kullanılarak yürüyüş biyometrisine dayanan kullanıcı doğrulama için birçok yaklaşım önerilmiştir [26-28]. Weiss vd. çalışmasında telefonun dahili ivmeölçer sensör bilgilerinden elde edilen 43 istatistiksel öznitelikler kullanılarak boy, kilo ve cinsiyet gibi yumuşak biyometrik özellikler belirlenmiştir [29]. Diğer bir çalışmada Jain vd. CT için akıllı telefonun hızölçer ve jiroskop sensörlerinin yakaladığı bilgi kombinasyonu kullanılmıştır [30]. Ankita vd. çalışmalarında ise, akıllı telefonların yerleşik sensörlerinden elde edilen yürüyüş verilerini kullanarak CT için bir yaklaşım geliştirmişlerdir. Sensör işaretlerinin histogramlarına ait istatistiksel öznitelikler kullanılmıştır. Önerilen yaklaşımın performansı, iki farklı akıllı telefon kullanılarak toplanan veri setleri üzerinde değerlendirilmiştir. Bu veri kümeleri 109 denekten toplam 654 yürüyüş verisi içermektedir. Deneysel sonuçları, önerilen yaklaşımın sınıflandırma doğruluğunun mevcut yöntemlerden daha yüksek olduğunu gösterdiklerini belirtmişlerdir. Ayrıca, iki farklı akıllı telefon kullanılarak toplanan yürüyüş verileri üzerinde yapılan deneylerden elde edilen sonuçlar, CT için önerilen algoritmanın performansının iki veri setinde tutarlı olduğunu göstermişlerdir [31]. Bu çalışmaların yanı sıra CT için insan hareketlerinin kullanıldığı çalışmalar da bulunmaktadır [32-35]. Kamile Nur Seviş yapmış olduğu tez çalışmasında cep telefonundaki ivmeölçeri kullanarak cinsiyet tespitinin başarıyla gerçekleştirildiğini belirtmiştir [32].

Bu çalışmada kişilerin farklı bölgelerine takılan sensörlerden elde edilen fizyolojik işaretler kullanılarak CT gerçekleştirilmiştir. Bu amaçla üç (3) farklı öznitelik çıkarım yaklaşımı önerilmiştir. Sensörlerden elde edilen işaretlere Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ), Bir Boyutlu Sağlam Yerel İkili Örüntüler (1B-SYİÖ) ve Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-SYİÖ) yöntemleri ile işaretlere dönüşüm uygulanmıştır. Dönüşüm işlemlerinden sonra yeni oluşan işaretlerden istatistiksel öznitelikler (ortalama, standart sapma, enerji, entropi, korelasyon, ardışık mutlak farklar, basıklık, çarpıklık, medyan, minimum, maksimum ve varyasyon katsayısı) elde edilmiştir. Bu öznitelikler kullanılarak farklı makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen sonuçlara bakıldığında önerilen yeni yaklaşımlar sayesinde sensör işaretleri kullanılarak CT işleminin yüksek bir başarı oranı ile gerçekleştirildiği belirlenmiştir.

Bu çalışmada, ilk kısımda çalışma konusu hakkında literatür çalışması ve cinsiyet tanıma için genel bilgiler sunulmuştur. İkinci kısımda, çalışmada kullanılan veri seti hakkında bilgiler verilmiştir. Üçüncü kısımda, önerilen öznelik çıkarım yaklaşımları, elde edilen istatistiksel öznelikler ve CT'a sistemi açıklanmıştır. Dördüncü kısımda, elde edilen sonuçlar ayrıntılı olarak verilmiştir. Beşinci kısımda ise sonuçlar tartışılmıştır.

## 2. VERİ SETİ (DATA SET)


Bu çalışmada önerilen yöntemleri test etmek için UCI veri tabanında paylaşılan "Daily and Sports Activities Data Set" veri seti kullanılmıştır [12-13]. Veri seti, 19 hareket (aktivite) için 8 farklı (4 erkek-4 kadın) kişinin belirli noktalarına (vücutun göğüs hizasına, sağ el bileğine, sol el bileğine, sağ bacağa ve sol bacağa) takılan sensörlerden elde edilmiştir. Sensör işaretleri 5 dakika boyunca deneklerin belirlenen hareketleri yapması ile kayıt altına alınmıştır. Daha sonra 5 dakikalık veriler 5'er saniyelik segmentlere (parçalara) ayrılmıştır. Her kişi için her harekete ait 60 kayıt bulunmaktadır. Toplamda  $19 \times 8 \times 60 = 9120$  kayıt bulunmaktadır. Bu 19 hareket Tablo 1'de verilmiştir.

**Tablo 1.** Çalışmada kullanılan 19 farklı hareket (19 different motion)

Hareket Kodu	Hareket Adı
H1	oturma hareketi
H2	ayakta durma hareketi
H3	sırt üstü yatma hareketi
H4	sağ tarafa yatma hareketi
H5	merdiven çıkma hareketi
H6	merdiven inme hareketi
H7	asansörde ayakta durma hareketi
H8	asansör hareket halindeyken ayakta durma hareketi
H9	otoparkta yürüme hareket
H10	4km/s hızla yere paralel koşu bandında yürüyüş hareketi
H11	4km/s hızla yere 15 derecelik açı ile koşu bandı yürüyüş hareketi
H12	8km / saat'lik hızla koşma hareketi
H13	step egzersiz yapma hareketi
H14	eliptik bisiklet hareketi
H15	yatay pozisyonda bisiklet sürme hareketi
H16	dikey pozisyonda bisiklet sürme hareketi
H17	kürek çekme hareketi
H18	sıçrama hareketi
H19	basketbol oynama hareketi

Çalışmada kullanılan her sensör ünitesinin içinde üç eksenli bir ivmeölçer, üç eksenli bir jiroskop ve üç eksenli bir manyetometre bulunmaktadır. Her biri üç adet üç eksenli cihaza sahip beş adet sensör birimi olduğu için, her bir sensör ünitesinden toplam dokuz adet işaret kaydedilmektedir. Kaydedilen 9 işaret sırasıyla X,Y,Z ivmeölçer, jiroskop ve manyetometre bilgilerini içermektedir. Bu çalışmada kullanılan sensör verileri aşağıdaki Şeki 1'de olduğu gibi

deneklere takılarak belirlenen hareketlerin yapılması sonucunda elde edilmiştir [33].



**Şekil 1.** Sensörlerin vücudun 5 farklı bölgesine takılmasının ve veri toplama sisteminin gösterimi (Display of the sensors in the 5 different regions of the body and the data collection system)

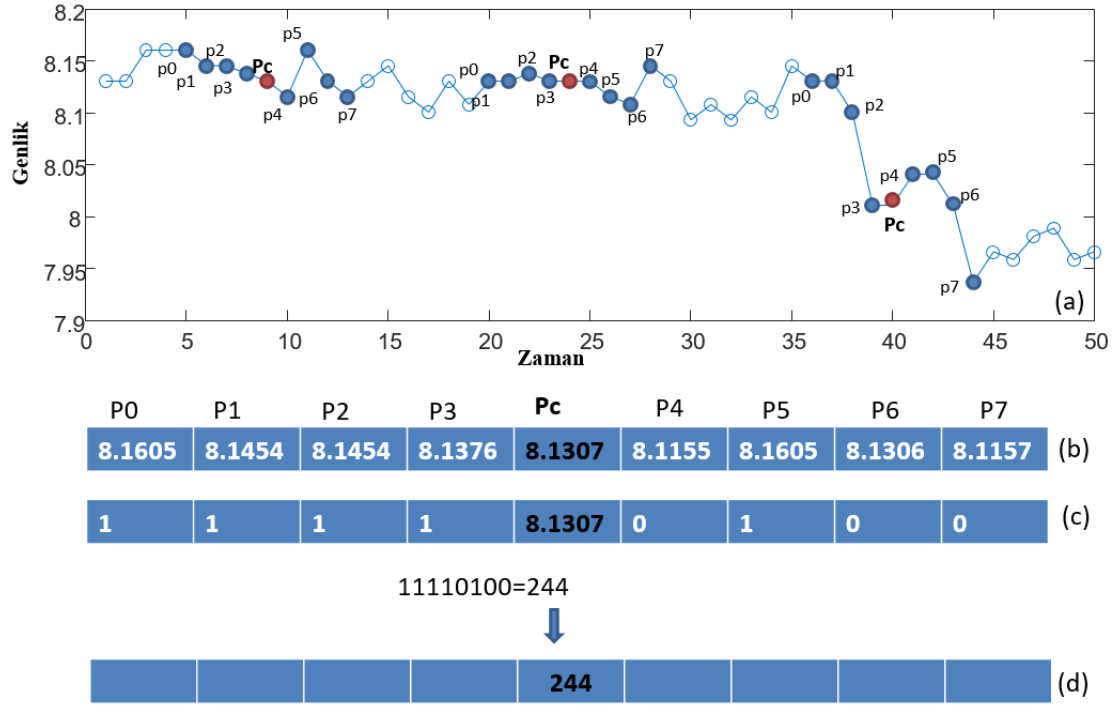
## 3. METOT (METHOD)

### 3.1. Bir Boyutlu Yerel İkili Örüntüler (One-Dimensional Local Binary Patterns)

Bu çalışmada, genellikle iki boyutlu olarak görüntü işlemede yaygın bir şekilde kullanılan yerel ikili örüntüler (YİÖ) yöntemi tek boyutlu hale getirilerek ham işaretlerden öznelik çıkarım yöntemi olarak geliştirilmiştir [36]. Bu amaçla, çeşitli sensör gruplarından kayıt edilen işaretler analiz edilerek bu işaretlerdeki öznelikler geliştirilen Bir (1) Boyutlu Yerel İkili Örüntü (1B-YİÖ) yöntemi kullanılarak çıkarılmıştır. Aşağıdaki Şekil 2'de 1B-YİÖ yöntemi ile öznelik çıkarım aşamaları adım adım anlatılmıştır.

Şekil 2'de gösterildiği gibi işaret üzerindeki her nokta kendisinden önce ve sonraki komşuları ile karşılaştırılarak 1B-YİÖ operatörü oluşturulmaktadır. Karşılaştırma sonucu elde edilen ikili dizge daha sonra onlu tabana çevrilerek her nokta için 1B-YİÖ etiketleri elde edilmektedir. İkili dizge oluşturmak için P kadar komşu alınmaktadır. Daha sonra,  $P_c$  merkez işaretin öncesinde ve sonrasında  $P/2$  kadar nokta alınmaktadır (Şekil 2(b)).  $P=8$  için merkez noktanın ( $P_c$ ) öncesinde ( $P_0, P_1, P_2, P_3$ ) ve sonrasında ( $P_4, P_5, P_6, P_7$ ) kadar komşu değer alınması Şekil 2(c)'de gösterilmiştir. Tüm komşular merkez nokta ile karşılaştırılmaktadır. Eğer komşu ( $P_i$ ) değer merkez ( $P_c$ ) değerden büyük ise "1" diğer durumlarda "0" olarak etiketlenmektedir (Şekil 2(c)). Karşılaştırma işlemi Eş. 1 ile işaret üzerindeki tüm noktalar için gerçekleştirilmektedir.  $P_c$  ve  $P_i$  ham işaret üzerindeki bir noktalar olmak üzere, 1B-YİÖ Eş. 1, Eş. 2 ile elde edilmektedir.

$$t = P_i - P_c \quad (1)$$



**Şekil 2.** 1B-YİÖ kullanılarak öznelilik çıkarımı a) ham sensör işaretlerine ait bir bölüm b) işaretlere ait değerler c) merkez değer komşu değerlerle karşılaştırılarak ikili dizginin oluşturulması d) onlu taban karşılığı  
(Feature extraction using the 1D-LBPs (a) a section of raw sensor signals (b) values of signals (c) the creation of a binary string by comparing the central value with the neighboring values (d) decimal base)

$$1B-YIO(x) = \sum_{i=0}^7 F(t)2^{7-i} \quad burada \quad F(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases} \quad (2)$$

Burada sırayla  $P_i$  ve  $P_c$  komşu değerler ile merkez değeri göstermektedir. Eş. 1 ile ikili dizge oluşturulduktan sonra bu ikili değer onlu tabana çevrilerek  $P_c$  değerinin 1B-YİÖ değeri olarak etiketlenmektedir (Şekil 2(d)). Bu işlemler işaret boyunca tüm noktalar için gerçekleştirilir. Şekil 2'deki işlemler tüm işaretlere uygulandığında işaret değerleri 0 ile 255 arasında değişen değerlere dönüşmektedir. Bu değerler yerel ikili örüntüler olarak isimlendirilmektedir. Bu değerlerin her birine ait frekans değeri bir örüntüyü ifade eder. 1B-YİÖ işaretin histogramı alındığında 256 adet farklı örüntünün olduğu görülebilir.

### 3.2. Bir Boyutlu Sağlam Yerel İki Örüntüler (One-Dimensional Robust Local Binary Patterns)

1B-YİÖ yönteminin işaretlerdeki gürültüye daha duyarlı hale getirmek için bu bölümde yeni bir yaklaşım önerilmiştir. Bu yaklaşım Zhao vd. [37] görüntü sınıflandırma için önerdikleri yerel ikili örüntüler tabanlı yaklaşımlarından geliştirilmiştir. İşaret üzerindeki ele alınan merkez değer ( $P_c$ ) ile komşular ( $P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7$ ) için ortalama bir değer hesaplanmaktadır. Bu ortalama değer, merkez değer ile komşular arasındaki gürültünün etkisini düşürecektir. Önerilen 1B-SYİÖ yaklaşımı için operatör Eş. 3, Eş. 4 ve Eş. 5 ile hesaplanmaktadır. Bu yöntemde işaretlerdeki gürültüye

daha duyarlı hale getirmek için merkez değer ( $P_c$ ) yerine pencere içine giren tüm işaretlerin ortalama değeri (Eş. 3) kullanılmıştır.

$$ORT = \frac{P_c + \sum_{i=0}^7 P_i}{9} \quad (3)$$

$$t = P_i - ORT \quad (4)$$

$$1B-SYIO(x) = \sum_{i=0}^7 F(t)2^{7-i} \quad burada \quad F(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases} \quad (5)$$

### 3.3. Ağırlıklandırılmış Sağlam Yerel İki Örüntüler (Weighted One-Dimensional Robust Local Binary Patterns)

Bu yöntemde işaretlerdeki gürültünün etkisini azaltmak için merkez değer ( $P_c$ ) komşu değerlere göre ağırlıklandırılmıştır. Merkez değer etkisi komşu değerlere göre Eş. 6, Eş. 7, Eş. 8, Eş. 9 ve Eş. 10 ile hesaplanmıştır. Merkez değer ağırlıklandırma işleminden sonra diğer aşamalar 1B-YİÖ işlemleri gibidir.

$$ORT = \frac{P_c + \sum_{i=0}^7 P_i}{9} \quad (6)$$

$$\alpha = \frac{P_c}{ORT} \tag{7}$$

$$WPC = \frac{\alpha P_c + \sum_{i=0}^7 P_i}{8 + \alpha} \tag{8}$$

$$t = P_1 - WPC \tag{9}$$

$$A-1B-SYIO(x) = \sum_{i=0}^7 F(t)2^{7-i} \quad \text{burada } F(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases} \tag{10}$$

Burada  $\alpha$  merkez deęerin komşu deęerler ile merkez deęerin ortalamaları üzerindeki etkisini belirten parametredir. WPC (Weighted P<sub>c</sub>) ise merkez deęerin komşu deęerler üzerindeki aęırlığını belirtmektedir.

### 3.4. İstatiksel Öznitelikler (Statistical Features)

Veri madencilięi ve makine öęrenmesi çözümlerinin en önemli ön aşamalarından biri yapılacak analizde kullanılacak özniteliklerin belirlenmesidir [38]. Çünkü öznitelikler kullanılarak farklı metotların test edilmesi (karşılaştırılması) sayesinde sonuçların yorumlanması ve çalışmanın karakterize edilmesi daha kolay bir hale dönüşmektedir [38-40]. Bu çalışmada, belirtilen S işaretinin uzunluğu N olmak üzere, bu işarete yukarıdaki 1B-YİÖ yöntemler uygulandıktan sonra oluşan yeni işaretin üzerindeki deęerleri  $X = \{X_1, X_2, \dots, X_N\}$  olduğunu varsayarak bu işareten elde edilen istatistiksel öznitelikler Tablo 2’de verilmiştir.

### 3.5. Performans Ölçütleri (Performance criteria)

Çalışmada önerilen yöntemlerin performansını göstermek için doğruluk, hassaslık, hatırlatma ve f-ölçütleri

**Tablo 2.** İşaretlerden elde edilen istatistiksel özellikler (Statistical properties obtained from signals)

No	Öznitelik	Formül
1	Ortalama	$f1 = \frac{\sum_{i=1}^N X_i}{N}$
2	Standart Sapma	$f2 = \sqrt{\frac{\sum_{i=1}^N (X_i - f1)^2}{N}}$
3	Enerji	$f3 = \sqrt{\frac{\sum_{i=1}^N (X_i)^2}{N}}$
4	Entropi	$f4 = -\sum_{i=1}^N \frac{X_i}{f3} \log\left(\frac{X_i}{f3}\right)$
5	Korelasyon	$f5 = \sum_{i=1}^N \frac{i * X_i - f1}{\sigma_x}$
6	Ardışık mutlak farklar	$f6 = \frac{\sum_{i=1}^N  X_{i+1} - X_i }{N}$
7	Basıklık	$f7 = \frac{\sqrt{N(N-1)}}{N-2} \left( \frac{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^3}{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^2} \right)^{3/2}$
8	Çarpıklık	$f8 = \frac{N-1}{(N-2)(N-3)} \left[ (N+1) \left( \frac{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^4}{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^2} \right) - 3 \right] + 6$
9	Medyan	$F9 = (n+1)/2$ .ci eleman
10	Minimum	$f10 = \min\{X_1, X_2, X_3, X_4, \dots, X_N\}$
11	Maksimum	$f11 = \max\{X_1, X_2, X_3, X_4, \dots, X_N\}$
12	Varyasyon katsayısı	$f12 = \frac{f1}{f2}$

kullanılmıştır. Bu başarı ölçütleri aşağıdaki Eş. 11, Eş. 12, Eş. 13 ve Eş. 14 de olduğu gibi hesaplanmaktadır [40].

$$\text{Doğruluk (Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (11)$$

$$\text{Kesinlik (Precision)} = TP/(TP + FP) \quad (12)$$

$$\text{Duyarlılık (Recall)} = TP/(TP + FN) \quad (13)$$

$$F - \text{Ölçütü (F - Measure)} = \frac{2(\text{Recall} * \text{Precision})}{(\text{Recall} + \text{Precision})} \quad (14)$$

Bu denklemlerde T, F, P ve N sırasıyla doğruyu, yanlış, pozitif ve negatif ifade etmektedir. Örneğin, TP doğru sınıflandırılan pozitif örnek sayısını; FN ise yanlış sınıflandırılan negatif örnek sayısını göstermektedir.

- Doğruluk: Başarının tespiti için kullanılan en popüler ve basit yöntemdir ve bu oran doğru sınıflandırılmış (TP+TN) örnek sayısının, toplam örnek sayısına (TP+TN+FP+FN) oranı olarak tanımlanmaktadır.
- Kesinlik: Sınıflandırıcı sonucunun kesinlik derecesini verir. Pozitif olarak etiketlenen örneklerin sayısının (TP) pozitif olarak sınıflandırılmış toplam örneğe (TP+FP) oranıdır.
- Duyarlılık: Pozitif olarak etiketlenmiş örneklerin (TP) gerçekten pozitif olan örneklerin (TP+FN) toplam sayısına oranıdır.
- F-Ölçütü: Kesinlik ve duyarlılık metrikleri kullanılarak hesaplanmaktadır. Sistemin, kesinlik ve ya duyarlılık yönüne doğru optimize edilmesinde kullanılmaktadır.

### 3.6. Önerilen Cinsiyet Tanıma Sistemi (Proposed Gender Identification System)

Bu çalışmada önerilen cinsiyet tanıma sistemi Şekil 3'te gösterilmiştir. Önerilen sistem 5 aşamadan oluşmaktadır. Her aşamada gerçekleşen işlemler aşağıda kısaca özetlenmiştir.

- Blok 1-2: Bu aşamada kişilerin 5 farklı bölgesine takılmış ivmeölçer, manyetometre ve jiroskop sensörlerinden işaretler ölçülmüştür. Belirlenen 19 farklı hareket için işaretler elde edilmiştir.
- Blok 3: Bu aşamada elde edilen işaretlere 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ dönüşümler uygulanmıştır. Bu dönüşümler sonucunda farklı işaretler oluşmaktadır. Bu


işaretler üzerindeki tüm değerler 0-255 arasındaki değerlerden oluşmaktadır.

- Blok 4: Bu aşamada yeni oluşan 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ işaretlerin histogramları oluşturulmaktadır.
- Blok 5: Bu blokta histogramlardan istatistiksel öznitelikler elde edilmektedir. Bu öznitelikler Tablo 2'de verilmiştir.
- Blok 6: İstatistiksel öznitelikler kullanılarak Karar Destek Vektörleri (Support Vector Machine, SVM (radial basis çekirdek fonksiyonu)), Random Forest( RF), Yapay Sinir Ağları (YSA), K en yakın komşu (Knn (K=3)) gibi farklı makine öğrenmesi yöntemleri ile 10 katlı çapraz geçerlilik testine göre sınıflandırma işlemleri gerçekleştirilmiştir.

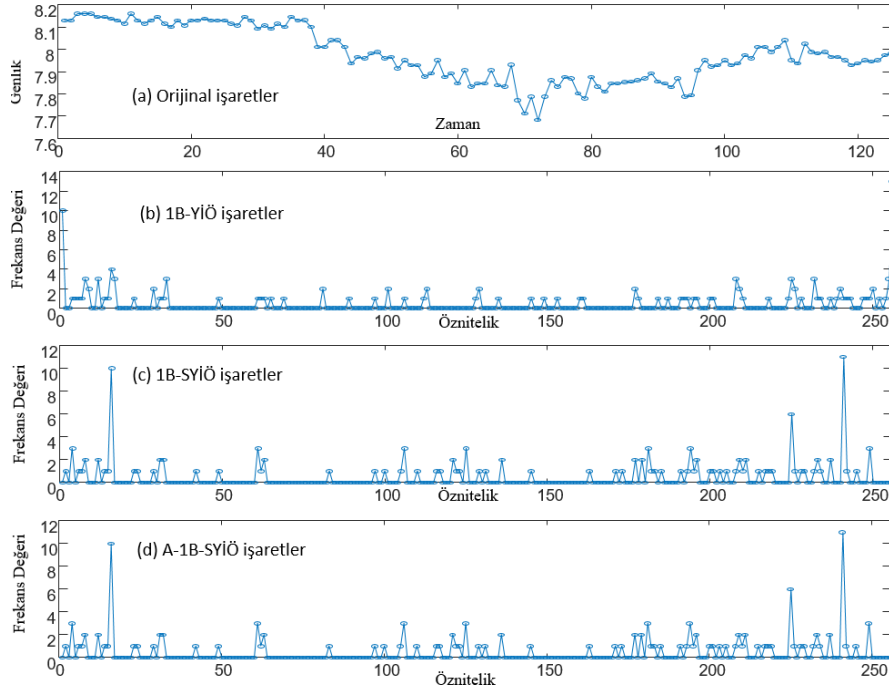
## 4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Çalışmada kullanılan veri seti 4 erkek ve 4 kadın bireyden 19 farklı hareket için elde edilen işaretlerden oluşmaktadır. Her harekete ait işaretlerin uzun (5 dakikalık kayıtlar) olmasından dolayı işaretler 60 segmente (5'er saniyelik kayıtlara) bölünmüştür. Dolayısıyla veri seti 19x8x60=9120 işaretten oluşmaktadır. Öncelikle işaretlere 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ yöntemleri uygulanarak, oluşan yeni işaretlerden istatistiksel öznitelikler çıkarılmıştır. Önerilen yöntemlerin işaret üzerindeki etkisi aşağıdaki örnekte verilmiştir. Oturma aktivitesi için kadın ve erkek deneklere takılı aynı sensörden (ivme sensörü X eksen) ölçülen işaretlere 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ uygulandıktan sonra elde edilen yeni işaretler Şekil 4 ve Şekil 5'te verilmiştir.

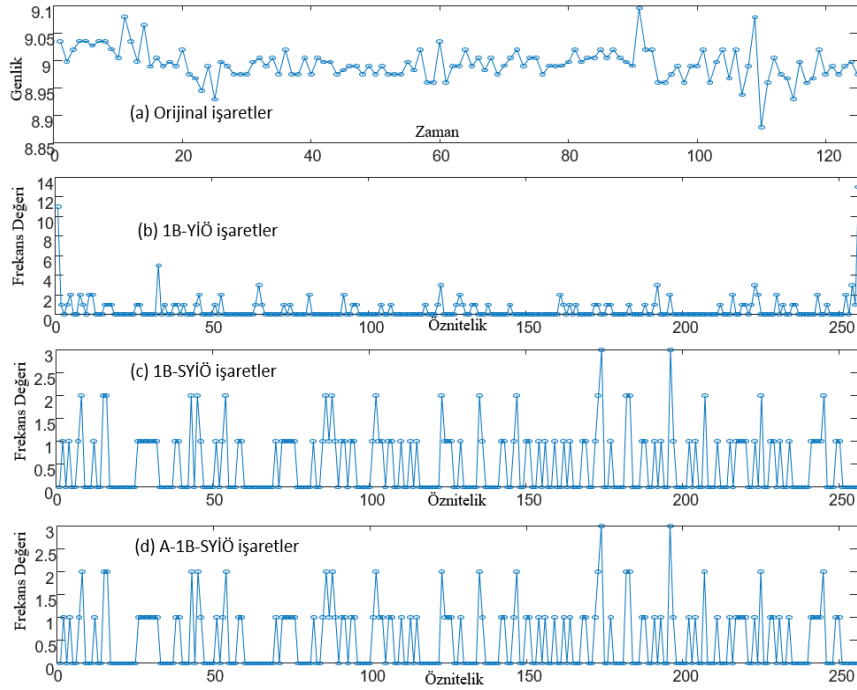
Şekil 4'te erkek deneklerin gövde bölgesine takılı ivme sensörünün X ekseninden elde edilen işaretler ve bu işaretlere önerilen yöntemlerin uygulanması sonucu oluşan 1B-YİÖ işaretler görülmektedir. İşaretlere bakıldığında 1B-YİÖ ile elde edilen işaretin diğer 1B-SYİÖ ve A-1B-SYİÖ işaretlerinden farklı olduğu görülmektedir. Bunun yanı sıra 1B-SYİÖ ve A-1B-SYİÖ işaretleri çok küçük farklılıklarla birbirinden farklılık göstermektedir. Cinsiyetlerin ayrıştırılması için farklı örüntülerin elde edilmesi önemli olmaktadır. Şekil 5'te kadın için aynı sensör ve aynı eksen için ölçülen işaretler verilmiştir. Kadın ve erkek için bu işaretlerin birbirinden ayrıştığı görülebilir. Cinsiyet tanıma için çıkarılan öznitelikler ile RF, Knn, YSA ve SVM gibi farklı makine öğrenmesi yöntemleri kullanılarak 10-katlı çapraz geçerlilik testine göre sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırma aşamasında Weka açık kaynak kodlu yazılım kullanılmıştır. 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ işaretlerinden elde edilen öznitelikler kullanılarak gözlenen başarı oranları Tablo 3'te verilmiştir.



Şekil 3. Cinsiyet Tanıma Sistemi (Gender Identification System)



**Şekil 4.** Erkek için oturma hareketine ait işaretler a) Orijinal işaretler b) 1B-YİÖ işaretler c) 1B-SYİÖ işaretler d) A-1B-SYİÖ işaretler  
(Signals of sitting motion for the male (a) Original signals (b) 1D-LBPs signals (c) 1D-RLBPs signals (d) W-1D-RLBPs signals)



**Şekil 5.** Kadın için oturma hareketine ait işaretler a) Orijinal işaretler b) 1B-YİÖ işaretler c) 1B-SYİÖ işaretler d) A-1B-SYİÖ işaretler  
(Signals of sitting motion for the female (a) Original signals (b) 1D-LBPs signals (c) 1D-RLBPs signals (d) W-1D-RLBPs signals)



Tablo 3'e bakıldığında en yüksek başarı oranı A-1B-SYİÖ dönüşümü ile elde edilen işaretlerden çıkarılan öznelikler ile gözlenmiştir. Başarı oranı %97,28 olarak Knn sınıflandırma metodu ile elde edilmiştir. A-1B-SYİÖ dönüşümü ile cinsiyet tanıma için 1B-YİÖ ve 1B-SYİÖ yöntemlerine göre daha ayrıştırıcı öznelikler sağlanmıştır. Genel olarak diğer sınıflandırma metotları ve öznelik çıkarım yöntemleri için de yüksek başarı oranları gözlenmiştir. Kullanılan sınıflandırma metotları arasında en başarılı Knn metodu olduğundan diğer sınıflandırma denemelerimizde Knn metodu kullanılmıştır. A-1B-SYİÖ öznelikler kullanılarak Knn ile gözlenen performans ölçütleri Tablo 4'te verilmiştir.

Tablo 4'e bakıldığında kadın tanıma oranının (TP Oranı=%97,9) erkek tanıma oranına (TP Oranı=%96,7) göre daha yüksek olduğu görülmektedir.

Hangi hareketin CT'da daha etkin olduğunu belirtmek için her hareket için sınıflandırma işlemleri gerçekleştirilmiştir. Veri setindeki 19 farklı hareket için 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ öznelikler kullanılarak Knn ile elde edilen sonuçlar Tablo 5'te gösterilmiştir. Tablo 5'e bakıldığında

önerilen öznelik çıkarım yöntemleri ile CT için yüksek sonuçlar elde edildiği görülmektedir. H9 (otoparkta yürüme), H10 (koşu bandı üzerinde yürüme), H11 (koşu bandı üzerinde 15 derece eğimli yürüme), H12 (koşu bandında koşma), H13 (step üzerinde egzersiz) ve H18 (sıçrama) hareketleri için tüm öznelik grupları ile %100 başarı elde edilmiştir. En düşük başarı H7 (asansörde ayakta durmak) ve H8 (asansörde dolaşmak) hareketleri için gözlenmiştir. Asansörde ayakta durmak ve yürüme hareketlerin yerde ayakta durma ve yürüme hareketlerinden CT'da farklı sonuç üretmesi ilginç bulunmuştur. Öznelik gruplarının ortalama başarısına bakıldığında en yüksek başarı A-1B-SYİÖ ile %97,71 olarak gözlenmiştir. Ancak diğer yöntemlerin de CT için kabul edilebilir yüksek sonuçlar ürettiği görülmektedir. Sensör işaretlerinden Tablo 2'de belirtilen 12 adet istatistiksel öznelik çıkartılmıştır. Bu istatistiksel özneliklerin her birinin CT'da etkinliğini belirtmek için her biri için ayrı ayrı sınıflandırma işlemleri gerçekleştirilmiştir. 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ öznelik grupları için Knn ile elde edilen başarı oranları Tablo 6'da verilmiştir.

**Tablo 3.** Cinsiyet tanıma başarı oranları (%) (Gender identification success rates (%))

İşaretler	Veri Boyutu	RF	SVM	Knn	YSA
1B-YİÖ	9120x541	92,44	93,07	96,04	89,41
1B-SYİÖ	9120x541	93,77	95,25	96,72	91,27
A-1B-SYİÖ	9120x541	94,29	96,49	97,28	92,10

**Tablo 4.** A-1B-SYİÖ öznelikleri için Knn performans ölçütleri sonuçları (Knn performance metrics results for W-1D-RLBPs features.)

Cinsiyet	TP Oran (TP Rate)	FP Oran (FP Rate)	Hassaslık (Precision)	Duyarlılık (Recall)	F-Ölçütü (F-Measure)
Erkek	0,967	0,021	0,978	0,967	0,973
Kadın	0,979	0,033	0,967	0,979	0,973
Ortalama	0,973	0,027	0,973	0,973	0,973

**Tablo 5.** Hareketlere Göre Cinsiyet Tanıma (Gender identification based on movements)

Hareket	#Öznelik	1B-YİÖ(%)	1B-SYİÖ(%)	A-1B-SYİÖ(%)
H1	540	94,58	97,92	97,92
H2	540	92,29	98,54	98,96
H3	540	90,63	90,42	95,83
H4	540	92,50	97,92	98,54
H5	540	99,79	100	100
H6	540	98,96	99,38	99,38
H7	540	86,88	85,63	86,67
H8	540	84,58	87,08	87,08
H9	540	100	100	100
H10	540	100	100	100
H11	540	100	100	100
H12	540	100	100	100
H13	540	100	100	100
H14	540	99,79	100	100
H15	540	99,79	100	100
H16	540	99,79	99,79	99,58
H17	540	99,58	99,58	99,79
H18	540	100	100	100
H19	540	88,54	91,88	92,71
Başarı Ortalaması		96,20	97,27	97,71

Tablo 6'ya bakıldığında en başarılı özneliğin entropi olduğu görülmektedir. 3 öznelik grubu için de entropi özneliği kullanılarak yüksek sonuçlar gözlenmiştir. Sadece entropi özneliklerin kullanılması ile 1B-YİÖ için %94,56, 1B-SYİÖ için %97,05 ve A-1B-SYİÖ için ise %97,06 başarı gözlenmiştir. En başarısız öznelik ise ortalama ve minimum özneliklerinin olduğu Tablo 6'dan görülmektedir. Öznelik grubu olarak ise A-1B-SYİÖ ile 1B-YİÖ ve 1B-SYİÖ öznelik gruplarına göre daha başarılı bulunmuştur. Genellikle A-1B-SYİÖ yöntemi tüm sınıflandırma işlemlerinde CT'da diğer yöntemlere göre daha etkin öznelikler sağladığı tespit edilmiştir.

Veri seti ivmeölçer, jireskop ve manyotemetre sensörlerinden elde edilen işaretlerden oluşmaktadır. 5 birim sensör grubunun tümünde birer adet ivmeölçer, jireskop ve manyotemetre sensörleri bulunmaktadır. Her sensör türü eşit sayıda kullanılmıştır. Sensör türüne göre elde edilen başarı oranları Tablo 7'de gösterilmiştir.

Tablo 7'den görüldüğü gibi en başarılı sonuçlar ivmeölçer sensöründen elde edilen öznelikler ile elde edilmiştir. En yüksek başarı oranları A-1B-SYİÖ öznelik grubu ile gözlenmiştir. A-1B-SYİÖ ile elde edilen öznelik grubunu kullanarak %91,33 başarı gözlenmiştir. Sensör türlerine göre

de A-1B-SYİÖ ile elde edilen öznelikler diğer 1B-YİÖ ve 1B-SYİÖ yöntemleri ile elde edilen özneliklere daha başarılı sonuçlar gözlenmiştir.

Sensörler kişilerin gövde (göğüs hizası), sağ-sol kollar ve sağ-sol bacaklara bağlanmıştır. Bölgelerin CT üzerinde etkisini belirtmek için her bölgeden elde edilen işaretler kullanılarak öznelik grupları oluşturulmuştur. Bölgelere göre 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ öznelik gruplarının Knn ile başarı oranları Tablo 8'de verilmiştir.

Tablo 8'de görüldüğü gibi CT için en iyi öznelikler gövde (göğüs hizası) bölümündeki sensörlerden elde edilmiştir. Gövde bölümünden elde edilen işaretler CT için daha ayırt edici bilgiler sağlamıştır. A-1B-SYİÖ yöntemi ile elde edilen öznelik grubu, diğer yöntemler ile elde edilen öznelik gruplarından daha başarılı sonuçlar elde edildiğini göstermiştir.

Önerilen öznelik çıkarım yaklaşımlarının başarısını belirtmek için aynı işaretlerden hem zaman hem de frekans düzleminde elde edilen öznelik grupları ile de karşılaştırma işlemleri gerçekleştirilmiştir. Frekans ve zaman düzleminde Tablo 2'de belirtilen öznelikler elde edilmiştir. Elde edilen başarı oranları Tablo 9'da verilmiştir.

**Tablo 6.** Özneliklere Göre Cinsiyet Tanıma (Gender Identification according to features)

Öznelik	#öznelik	1B-YİÖ	1B-SYİÖ	A-1B-SYİÖ
Ortalama	45	86,88	88,54	88,72
Standart Sapma	45	92,27	92,27	96,29
Enerji	45	92,17	96,05	96,04
Entropi	45	94,56	97,05	97,06
Korelasyon	45	92,57	96,45	96,12
Ardışık mutlak farklar	45	86,27	91,27	91,39
Medyan	45	84,58	84,58	83,68
Basıklık	45	91,78	94,48	94,47
Çarpıklık	45	90,99	91,61	91,92
Minimum	45	84,58	84,58	84,13
Maksimum	45	89,14	95,03	95,22
Varyasyon katsayısı	45	93,93	96,92	96,91
Başarı Ortalaması		89,98	92,40	92,66

**Tablo 7.** Sensör Türlerine Göre Cinsiyet Tanıma (Gender Identification by Sensor Types)

Sensör Türü	#öznelik	1B-YİÖ	1B-SYİÖ	A-1B-SYİÖ
Ivmeölçer	180	90,01	91,07	91,33
Jiroskop	180	86,83	86,71	89,21
Manyotemetre	180	88,66	89,31	89,43
Başarı Ortalaması		88,502	89,031	89,99

**Tablo 8.** Sensör Bağlantı Bölgesine göre Cinsiyet Tanıma (Gender Identification by Sensor port)

Bağlantı Bölgesi	#öznelik	1B-YİÖ	1B-SYİÖ	A-1B-SYİÖ
Gövde (Göğüs hizası)	108	86,43	87,46	87,46
Sağ Kol	108	83,90	85,24	85,46
Sol Kol	108	82,79	83,17	83,88
Sağ Bacak	108	83,34	82,39	84,49
Sol Bacak	108	83,03	84,23	86,34
Başarı Ortalaması		83,90	84,50	85,52

**Tablo 9.** Zaman ve Frekans Düzleminde Cinsiyet Tanıma (Gender Identification on Time Domain and Frequency Domain)

Öznitelik Grubu	#öznitelik	Başarı (Accuracy)	Hassaslık (Precision)	Duyarlılık (Recall)	F-Ölçütü (F-Measure)
1B-YİÖ	540	96,04	0,96	0,96	0,96
1B-SYİÖ	540	96,72	0,97	0,97	0,97
A-1B-SYİÖ	540	97,28	0,97	0,97	0,97
Zaman Düzlemi	540	89,43	0,89	0,90	0,89
Frekans Düzlemi	540	95,27	0,95	0,95	0,95

Tablo 9'a bakıldığında önerilen öznitelik çıkarım yöntemleri ile elde edilen istatistiksel öznitelikler ile zaman ve frekans düzleminde elde edilen özniteliklere göre daha yüksek başarı elde edildiği gözlenmiştir. Bu çalışmada önerilen 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ öznitelik çıkarım metotları CT'da frekans ve zaman düzleminin sağladığı istatistiksel özniteliklere göre çok daha başarılı bulunmuştur. Ayrıca frekans düzleminde işaretlerden elde edilen özniteliklerin CT'da zaman düzleminde aynı işaretlerden elde edilen aynı özniteliklere göre daha başarılı bulunmuştur.

## 5. SONUÇLAR (CONCLUSIONS)

Son yıllarda, giderek artan sayıda araştırmacı biyometrik kimlik sistemlerinin performansını arttırmak için insanların yaş, cinsiyet ve etnik kökenleri gibi yumuşak biyometrik özelliklerine odaklanmışlardır. CT; demografik analiz, insan-makine etkileşimleri gibi çeşitli alanlarda potansiyel uygulamalara sahiptir. Bir kişinin yüzüne bakılarak, onu dinleyerek veya yürüyüşünü izleyerek cinsiyeti hakkında kolayca bilgi sahibi olunabilir. Ancak bilgisayar sistemlerinde birinin cinsiyetini belirlemek hala zor bir problemdir. Bu çalışmada sensör işaretleri kullanılarak CT işlemi gerçekleştirilmiştir. Bu amaçla sensör işaretleri kullanılarak 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ yeni öznitelik çıkarım yaklaşımları önerilmiştir. Önerilen yaklaşımlar ile elde edilen öznitelikler farklı makine öğrenmesi yöntemleri ile sınıflandırılmıştır. En başarılı sınıflandırma metodu Knn olarak gözlenmiştir. Knn kullanarak önerilen yaklaşımlar ile sırası ile %94,04, %96,72 ve %97,28 başarı oranları elde edilmiştir. A-1B-SYİÖ yöntemin CT için diğer iki yönteme göre daha etkin öznitelikler sağladığı tespit edilmiştir.

Ayrıca, çalışmada veri setinde gerçekleştirilen tüm hareketler ayrı ayrı CT gerçekleştirilmiştir. Tüm hareketler için kabul edilebilir yüksek başarı oranları gözlenmiştir. H9 (otoparkta yürüme), H10 (Koşu bandı üzerinde yürüme), H11 (Koşu bandı üzerinde 15 derece eğimli yürüme), H12 (Koşu bandında koşma), H13 (Step üzerinde egzersiz) ve H18 (sıçrama) hareketleri için tüm öznitelik grupları ile %100 başarı elde edilmiştir. En düşük başarı H7 (asansörde ayakta durmak) ve H8 (Asansörde dolaşmak) hareketleri için gözlenmiştir.

1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ yöntemlerinin uygulandığı sensör işaretlerinden 12 farklı istatistiksel öznitelik hesaplanmıştır. Hangi öznitelğin etkin olduğunu

belirtmek için yapılan denemelerde sadece entropi öznitelği ile %97,06 gibi yüksek bir başarı oranı gözlenmiştir.

Bunun yanında ivmeölçer, jireskop ve manyotometre sensörlerin CT üzerinde etkisini belirtmek için her sensör türü için sınıflandırma işlemi gerçekleştirilmiştir. Sırası ile %91,33, %89,21 ve %89,43 başarı oranları gözlenmiştir. Bu üç sensör türünün birlikte kullanılması daha uygun bulunmuştur.

CT için sensörlerin bağlı olduğu bölgelerin etkisi diğer bir deyişle işaretlerin elde edildiği bölgelerin etkisi ayrıca incelenmiştir. Gövde (göğüs hizası) bölümünden gözlenen işaretlerin CT'da kollar ve bacaklara göre daha etkin öznitelikler sağladığı görülmüştür.

Ayrıca bu çalışmada, önerilen yaklaşımların başarısını belirtmek için aynı işaretlerden hem zaman hem de frekans düzleminde elde edilen öznitelik grupları ile de karşılaştırılmıştır. Önerilen 1B-YİÖ, 1B-SYİÖ ve A-1B-SYİÖ öznitelik çıkarım metotları CT'da frekans ve zaman düzleminin sağladığı istatistiksel özniteliklere göre çok daha başarılı bulunmuştur. Yapılan tüm denemelerde A-1B-SYİÖ yaklaşımın diğer 1B-YİÖ ve 1B-SYİÖ yaklaşımlardan daha başarılı olduğu görülmüştür. Sonuç olarak önerilen öznitelik çıkarım yaklaşımların CT için etkin öznitelikler sağladığı görülmüştür. Önerilen yaklaşımların farklı işaretlere uygulanabileceği de düşünülmektedir.

## TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma Siirt Üniversitesi Rektörlüğü Bilimsel Araştırma Projeleri BAP Koordinasyon Birimi Koordinatörlüğü tarafından 2018-SİÜFEB-DR-009 no'lu proje olarak desteklenmiştir. Bu makalenin yazarları, verilen destekten dolayı Siirt Üniversitesi Rektörlüğü'ne teşekkür ederler.

## KAYNAKLAR (REFERENCES)

1. Cao, L., Dikmen, M., Fu, Y., & Huang, T. S., Gender recognition from body. In Proceedings of the 16th ACM international conference on Multimedia, 725-728. ACM., October, 2008.
2. Yu, S., Tan, T., Huang, K., Jia, K., & Wu, X., A study on gait-based gender classification. IEEE Transactions on image processing, 18 (8), 1905-1910, 2009.
3. Golomb, B. A., Lawrence, D. T., & Sejnowski, T. J., Sexnet: A neural network identifies sex from human faces. In NIPS, 1 (2), October 1990.

4. Harb, H., & Chen, L. (2003, July). Gender identification using a general audio classifier. In *Multimedia and Expo, ICME'03. Proceedings. 2003 International Conference on* (Vol. 2, pp. II-733). IEEE., 2003.
5. Li, X., Maybank, S. J., Yan, S., Tao, D., & Xu, D., Gait components and their application to gender recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 38 (2), 145-155, 2008.
6. Guo, G., Mu, G., & Fu, Y. (2009, September). Gender from body: A biologically-inspired approach with manifold learning. In *Asian Conference on Computer Vision*, Springer, Berlin, Heidelberg., 236-245, 2009.
7. Gutta, S., Huang, J. R., Jonathon, P., & Wechsler, H. Mixture of experts for classification of gender, ethnic origin, and pose of human faces. *IEEE Transactions on neural networks*, 11 (4), 948-960, 2000.
8. Moghaddam, B., & Yang, M. H., Learning gender with support faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24 (5), 707-711, 2002.
9. Li, Z., Zhou, X., & Huang, T. S., Spatial gaussian mixture model for gender recognition. In *Image Processing (ICIP), 2009 16th IEEE International Conference on* 45-48, IEEE., November 2009.
10. Chen, C., & Ross, A. (2011, October). Evaluation of gender classification methods on thermal and near-infrared face images. In *Biometrics (IJC), International Joint Conference on* (pp. 1-8). IEEE 2011.
11. Ng, C. B., Tay, Y. H., & Goi, B. M. Vision-based human gender recognition. A survey. *arXiv preprint arXiv. 1204.1611*, 2012.
12. Danisman, T., Bilasco, I. M., & Martinet, J. Boosting gender recognition performance with a fuzzy inference system. *Expert Systems with Applications*, 42 (5), 2772-2784, 2015.
13. Li, X., Maybank, S. J., Yan, S., Tao, D., & Xu, D. Gait components and their application to gender recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 38 (2), 145-155, 2008.
14. Lu, J., Wang, G., & Moulin, P., Human identity and gender recognition from gait sequences with arbitrary walking directions. *IEEE Transactions on Information Forensics and Security*, 9 (1), 51-61, 2014.
15. Igual, L., Lapedriza, A., & Borràs, R., Robust gait-based gender classification using depth cameras. *EURASIP Journal on Image and Video Processing*, 2013 (1), 1, 2013.
16. Gnanasivam, P., & Muttan, S., Gender classification using ear biometrics. In *Proceedings of the Fourth International Conference on Signal and Image Processing 2012 (ICSIP 2012)*, Springer, India. 137-148, 2013.
17. Li, X., Zhao, X., Fu, Y., & Liu, Y., Bimodal gender recognition from face and fingerprint. In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*, IEEE, 2590-2597, June 2010.
18. Wu, M., & Yuan, Y. (2014). Gender classification based on geometry features of palm image. *The Scientific World Journal*, 2014.
19. Thomas, V., Chawla, N. V., Bowyer, K. W., & Flynn, P. J. (2007, September). Learning to predict gender from iris images. In *Biometrics: Theory, Applications, and Systems, 2007. BTAS 2007. First IEEE International Conference on* (pp. 1-5). IEEE.
20. Li, X., Zhao, X., Fu, Y., & Liu, Y. (2010, June). Bimodal gender recognition from face and fingerprint. In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on* (pp. 2590-2597). IEEE
21. Shan, C., Gong, S., & McOwan, P. W. (2008). Fusing gait and face cues for human gender recognition. *Neurocomputing*, 71(10-12), 1931-1938.
22. Zhang, D., & Wang, Y. (2009, June). Gender recognition based on fusion of face and multi-view gait. In *International Conference on Biometrics* (pp. 1010-1018). Springer, Berlin, Heidelberg.
23. Jain, A. K., Nandakumar, K., Lu, X., & Park, U. (2004, May). Integrating faces, fingerprints, and soft biometric traits for user recognition. In *International Workshop on Biometric Authentication* (pp. 259-269). Springer, Berlin, Heidelberg.
24. Park, U., & Jain, A. K. (2010). Face matching and retrieval using soft biometrics. *IEEE Transactions on Information Forensics and Security*, 5(3), 406-415.
25. Thang, H. M., Viet, V. Q., Thuc, N. D., & Choi, D. (2012, November). Gait identification using accelerometer on mobile phone. In *Control, Automation and Information Sciences (ICCAIS), 2012 International Conference on* (pp. 344-348). IEEE.
26. Zhong, Y., & Deng, Y. (2014, September). Sensor orientation invariant mobile gait biometrics. In *Biometrics (IJC), 2014 IEEE International Joint Conference on* (pp. 1-8). IEEE.
27. Thang, H. M., Viet, V. Q., Thuc, N. D., & Choi, D. (2012, November). Gait identification using accelerometer on mobile phone. In *Control, Automation and Information Sciences (ICCAIS), 2012 International Conference on* (pp. 344-348). IEEE.
28. Zhang, Y., Pan, G., Jia, K., Lu, M., Wang, Y., & Wu, Z. (2015). Accelerometer-based gait recognition by sparse representation of signature points with clusters. *IEEE transactions on cybernetics*, 45(9), 1864-1875.
29. Weiss, G. M., & Lockhart, J. W. (2011, August). Identifying user traits by mining smart phone accelerometer data. In *Proceedings of the Fifth International Workshop on Knowledge Discovery from Sensor Data* (pp. 61-69). ACM.
30. Jain, A., & Kanhangad, V. (2016, March). Investigating gender recognition in smartphones using accelerometer and gyroscope sensor readings. In *Computational Techniques in Information and Communication Technologies (ICCTICT), 2016 International Conference on* (pp. 597-602). IEEE.
31. Jain, A., & Kanhangad, V. (2018). Gender classification in smartphones using gait information. *Expert Systems with Applications*, 93, 257-266.

32. Seviş, K. N. (2017). Biometrics for smartphones: age recognition, gender recognition and identification (Doctoral dissertation).
33. Altun, K., Barshan, B., & Tunçel, O. (2010). Comparative study on classifying human activities with miniature inertial and magnetic sensors. *Pattern Recognition*, 43(10), 3605-3620.
34. Barshan, B., & Yüksek, M. C. (2014). Recognizing daily and sports activities in two open source machine learning environments using body-worn sensor units. *The Computer Journal*, 57(11), 1649-1667.
35. Altun, K., & Barshan, B. (2010, August). Human activity recognition using inertial/magnetic sensor units. In *International Workshop on Human Behavior Understanding* (pp. 38-51). Springer, Berlin, Heidelberg.
36. 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*, 243, 209-219.
37. Zhao, Y., Jia, W., Hu, R. X., & Min, H. (2013). Completed robust local binary pattern for texture classification. *Neurocomputing*, 106, 68-76.
38. Var, E., & İnan, A. (2018). Sınıflandırma için diferansiyel mahremiyete dayalı öznelik seçimi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 33(1).
39. Kaya Y., Ertuğrul Ö.F., A novel feature extraction approach for text-based language identification: Binary patterns, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31 (4), 1085-1094, 2016.
40. Çelik, C., & Bilge, H. Ş. (2015). Feature selection with weighted conditional mutual information, *Faculty of Engineering and Architecture of Gazi University*, 30 (4), 585-596, 2015.

