

Akıllı Telefonların İvmeölçer Sensörü Yardımıyla Yürüyüş Deseni Analizi

Emrah AYDEMİR^{1*}, İbrahim KARSLIOĞLU²

¹ Kırşehir Ahi Evran Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kırşehir.

² Yozgat Bozok Üniversitesi, Sorgun Meslek Yüksekokulu, Bilgisayar Teknolojileri, Yozgat

*Sorumlu yazar e-posta: emrah.aydemir@ahievran.edu.tr, ORCID ID: <http://orcid.org/0000-0002-8380-7891>
ibrahim.karslioglu@bozok.edu.tr, ORCID ID: <http://orcid.org/0000-0002-2255-6611>

Geliş Tarihi: 09.01.2021

Kabul Tarihi: 05.04.2021

Öz

Spor alanlarında insan hareketlerini ölçme yeteneği performans ölçüm ve gelişimi için önemli konular arasındadır. Bu durum aynı zamanda klinik değerlendirmelerin de önemli bir parçasıdır. Özellikle elektromanyetik sistemler insan hareketlerini değerlendirmek için en yaygın kullanılan yöntemler arasında yer alır. Buradaki çalışmada 100 metre uzunluğunda bir koridorda 50 farklı kişinin yürüme verileri kullanılmıştır. Yürüme verileri akıllı telefon için geliştirilen bir yazılım ile ivmeölçer sensöründen elde edilmiştir. Verilere üç boyutlu Local Binary Pattern (LBP) yöntemi uygulanmış ve toplam 768 öznelik çıkarılmıştır. Farklı sınıflandırma algoritmaları ile testler yapılmış ve Subspace KNN ile %97,2 başarılı sınıflandırma elde edilmiştir. Cinsiyete göre yapılan sınıflandırmada ise %99,7 başarılı sınıflandırma elde edilmiştir. Bu yöntem ile yürüme bozukluğu tespitinde yüksek maliyetli cihazlar yerine daha ekonomik yöntemler geliştirileceği düşünülmektedir.

Anahtar kelimeler

Yürüyüş Tanıma;
İvmeölçer; Yürüyüş
Deseni; Akıllı Telefon

Gait Analysis of Smart Phones with The Help of The Accelerometer Sensor

Abstract

The ability to measure human movements in sports fields is among the important issues for performance measurement and development. This instance is also an important part of clinical evaluations. Electromagnetic systems are among the most widely used methods to evaluate human movements. In this study, walking data of 50 different people were used in a 100-meter-long corridor. The walking dataset was obtained from the accelerometer sensor with a software developed for the smartphone. Three-dimensional Local Binary Pattern (LBP) method was applied to the dataset and a total of 768 features were generated. Datasets were made with different classification algorithms and 97.2% successful classification was achieved with Subspace KNN. In the classification according to gender, 99.7% successful classification was obtained. With this method, it is thought that more economical methods will be developed instead of high-cost devices in detecting gait disorders.

Keywords

Gait Recognition;
Accelerometer; Gait
Pattern; Smart phone

© Afyon Kocatepe Üniversitesi

1. Giriş

Bir kişinin fizyolojik veya davranışsal özelliklerine göre otomatik olarak belirlenmesi biyometri alanının konusudur. Özellikle son zamanlarda büyük veride yaşanan artış ve yapay zekâdaki gelişmeler kişi tanımlama ve doğrulama konularına yönelik araştırma ve geliştirmelerde de artışa neden olmuştur. İnsanların kimliklerini doğrulamak amacıyla fizyolojik ya da davranışsal özellikleri kullanan teknoloji alanı biyometridir (Ben

Abdelkader *et al.* 2002). Biyometrik özellikler bir kişideki özelliğin bir başkasında birebir aynısının olmadığı fizyolojik farklılıklardır. Gözetim sistemlerinin yaygınlaşması ile birlikte özellikle uzaktan görme temelli insan tanımlama çalışmalarına ilgi artmaktadır. Bu durumun temel sebepleri arasında görsel izleme uygulamalarında otomatikleştirilmiş kişi tanıma sistemlerine duyulan ihtiyaç yer almaktadır. İnsanların yürüyüşü vücutlarının alt ve üst bölümlerinin senkronize bir hareketinden oluşur. Yürüyüş, bir bireyin yürüme

tarzını ifade eder ve benzersizdir. Benzersiz olması nedeniyle kişi tanımlamada kullanılan bir imza olduğu söylenebilir (Wang *et al.* 2003). İnsan yürüyüşü ortak hareket kalıplarına sahip olup vücudun hareket ettiği ritmik ve periyodik bir harekettir. Yani yüzlerce kas ve eklemin senkronize hareketlerinden oluşur (Bingham *et al.* 1995). İnsanların yürüyüşünde her defasında küçük sapmalarla farklılıklar olsa dahi büyük oranda simetrik olup kişiye özeldir (Murray *et al.* 1964). Kişiye özel olmasının temel nedenleri arasında adım süresi, duruş süresi ve salınım süresindeki farklılıklar (Dewar and Judge 1980) ile yer reaksiyon kuvveti profillerindeki farklılıklar (Balasubramanian *et al.* 2007) ve hareket aralığındaki farklılıklar (Shorter *et al.* 2008) yer alır. Yürüyüş tanıma yaklaşımları modele (Bouchrika and Nixon 2006, Cunado *et al.* 2003) ve görünüme (Lee *et al.* 2007, Liu *et al.* 2002) dayalı analiz olmak üzere iki kategoride toplanabilir.

Parmak izi, iris, yüz ve ses vb. biyometrik özelliklerin tanınmasında parmağın belirli bir noktaya bastırılması, gözün belirli bir bölmeğe yaklaştırılması ve bir noktaya karşı konuşma gibi kullanıcı etkileşimi gerektirir. Bu tür durumlar hem kullanıcıların biyometrik verilerinin kullanıldığını fark etmesi nedeniyle onları rahatsız eder hem de biyometrik tanıma sistemi kandırılabilir. Bu özelliği nedeniyle göze batmama avantajı vardır. Ayrıca yürüyüşün doğal olması nedeniyle taklit edilmesi de mümkün olmamaktadır. Yürüyüşün uzak bir mesafeden tespit edilebilen tek biyometrik özellik olduğu rahatlıkla söylenebilir. Tüm bunların yanı sıra yürüyüş dinamikleri farklı şekillerde ölçüldüğünde kullanıcının bunun farkına varmaması mümkün olabilir. Yürüyüş deseninin tanınması yürüyüş bozukluklarının tespiti için de temel oluşturacaktır.

2. Literatür Taraması

Lamar-León vd. (2012)'a göre yapılan bir çalışmada yürüyüş tanıma için CASIA-B veri tabanındaki yürüyüş görüntüleri kullanılmıştır. Arka plan çıkarma yaklaşımı kullanılarak üç boyutlu dijital görüntüler elde edilmiş ve yürürken insan vücudunun bölümleri arasındaki ilişkiyi yakalayarak %98,5 doğru sınıflandırma oranı elde etmiştir. CASIA-B veri tabanındaki yürüyüş görüntüleri kullanılarak farklı yürüyüş tanıma çalışmaları ile daha düşük

sınıflandırma başarısına sahip çalışmalar vardır (Arora *et al.* 2015, Chao *et al.* 2019, Goffredo *et al.* 2008, Tong *et al.* 2017). Bir başka çalışmada ise 28 kişiye ait yürüme anındaki gölge görüntüleri analiz edilmiş ve en yüksek başarı oranı olarak %94,3 elde edilmiştir (Iwashita *et al.* 2012). Gölge görüntülerinden yürüyüş tanıma ile ilgili birçok farklı çalışma literatürde vardır (Iwashita *et al.* 2014, Iwashita *et al.* 2010, Katiyar *et al.* 2014, Shinzaki *et al.* 2015, Stoica 2010, Verlekar *et al.* 2017, 2018). İnsanların yürüyüş görüntülerinin kamera ile kayıt altına alınması ve bunların analiz edilerek yapılan birçok farklı çalışma vardır (Connor and Ross 2018, Semwal *et al.* 2017, Zhao *et al.* 2006).

Yalabık vd. (Yalabık vd. 2008) tarafından bir diz hastalığı olan Osteoartrit (OA)'in tespit edilmesi ve derecelendirilmesi amacıyla bilgisayarlı yürüyüş analizi laboratuvarında veri toplanmıştır. Hastalığın derecesi, normal, başlangıç, orta ve ileri şeklinde derecelendirilmiştir. Toplam 40 denekten elde edilen veriler mahalanobis uzaklığı kullanılarak öznitelik çıkarımı yapılmıştır. Sınıflandırma işleminde ise %80 başarı oranı elde edilmiştir. Gouwanda ve Senanayake (2011) tarafından 11 sağlıklı denegin bacaklarına takılan dört adet jiroskoptan 10 metrelik yürüyüş mesafesinden veriler elde edilmiştir. Denekler hem normal yürüyüş gerçekleştirmiş hem de sol ve sağ ayak bileklerindeki 2,5 kg ağırlık ile yürümeleri istenmiştir. Bacak uzunluğu tutarsızlığı olan hastaların taklit edilmesi amacıyla yapılan çalışmada istatistiksel sonuçlar analiz edilmiştir.

Annadhorai vd. (2009)'a göre ise altı farklı sağlıklı genç denegin kalçasına takılan cep telefonu yardımıyla ivmeölçer verilerini toplamıştır. Yavaş, normal ve hızlı yürüme hızındaki bu veriler temel bileşen analizi (PCA) ile hesaplanan kümülanlarda boyut indirgemesi kullanılarak öznitelik çıkarımı yapılmıştır. Destek vektör makineleri (SVM) ile gerçekleştirilen sınıflandırmada %90,3 başarı oranı elde edilmiştir. Benzer şekilde Sprager ve Zazula (2009b) tarafından da deneklerin kalçasına yerleştirilen cep telefonu yardımıyla ivmeölçer sensörü kullanılarak veriler toplanmıştır. Altı farklı denegin normal, yavaş ve hızlı yürüme hızlarındaki verilerinden destek vektör makineleri yöntemi ile


%93,1 başarılı sınıflandırma elde edilmiştir. Si vd. (2019) geliştirdikleri özel bir ayakkabı yardımıyla basınç ve kuvvete dayalı direnç sensörlerinden veri elde etmiştir. Ayakkabının dört farklı noktasından kablosuz iletişim ile elde edilen sinyal verileri için beş farklı öznelik çıkarımı yapılmış ve %93,57 başarılı sınıflandırma elde edilmiştir. Bir başka çalışmada ise kemer üzerine yerleştirilen ivmeölçer kullanılarak 36 denegın yürüyüş verileri toplanmış ve yaklaşık %88 başarılı sonuçlar elde edilmiştir (Mantjarvi *et al.* 2005). Kullanıcıların sağ alt bacağına takılan ivmeölçer tabanlı bir başka sistem (Gafurov *et al.* 2006) ile kullanıcıların ayak bileklerine takılan iki eksenli jiroskop verilerinin kullanıldığı (Annadhorai *et al.* 2008) çalışmalar vardır. Bir başka çalışmada ise 59 denek üzerinde akıllı saatin içinde yer alan ivmeölçer ve jiroskop verileri kullanılmıştır (Johnston and Weiss 2015). İvmeölçer için en yüksek %98,3 ve jiroskop için en yüksek %94,8 başarı oranı elde edilmiştir. Zou vd. (2020) tarafından 118 denek üzerinde gerçekleştirilen ve akıllı telefonda elde edilen veriler ile hem kimlik doğrulama hem de kişi tanımlama çalışması yapılmıştır. Derin öğrenme tabanlı analizlerde kişi tanımlama için %93,5 ve kimlik doğrulama için ise %93,7 başarı oranı elde edildiği görülmüştür. Phillips vd. (2002) tarafından yapılan çalışmada yürüyüş çalışmalarının analizinde ayakkabı türü ve yüzey türünün etkili olduğu görülmüş olup yüzey türünün ayakkabı türüne oranla yaklaşık beş kat daha etki ettiği belirlenmiştir. İnsanların yürüyüş tarzlarından cinsiyetlerinin tanınması ile ilgili de birçok farklı çalışma vardır (Barclay *et al.* 1978, Barra *et al.* 2019, El-Alfy and Binsaadoon 2019, Xuelong Li *et al.* 2008). Benzer şekilde insanların yürüyüşlerinden kaç yaşında olduğunu tahmin eden farklı çalışmalar da vardır (Xiang Li *et al.* 2018, Makihara *et al.* 2011, Mansouri *et al.* 2017, Nabila *et al.* 2017).

3. Amaç ve Kapsam

Sensörlerden yararlanarak insanları yürüyüşlerinden ayırt etme zemine sensör yerleştirme (Addlesee *et al.* 1997), ayakkabıya sensör yerleştirme (Huang *et al.* 2007) veya vücuda sensör yerleştirme (Gafurov and Snekenes 2009) gibi farklı şekillerde olmaktadır. Buradaki çalışmada ekstra bir cihaz üretimi yapmadan, her kullanıcıda

bulunan bir android tabanlı akıllı telefonda yararlanılacaktır. Akıllı telefonlar ve akıllı saatler içerisinde ivmeölçer sensörü yani bir diğer adıyla akselometre vardır. İvme kuvvetinin ölçümünde kullanılan elektromekanik olan bu aygıt hareketi ve titreşimleri algılamada temel alınan bir aygıttır. Bu aygıt temel olarak aşağıdaki örnek verilen durumlarda kullanılır.

- Telefonun yatay konuma getirilince yatay durması ve dikey konumda dikey durması
 - Hareket halinde fotoğraf çekerken titreşimleri önleyerek daha net fotoğraflar elde edilmesi
 - Pusula uygulamaları ile yön bulunması
 - Telefonun y eksenindeki hareketlerini adım olarak kabul etme ve sağlık uygulamalarında kullanılması
 - Sabit disklerdeki ani hareketlerin algılanması ve okuma kafasının diske vurmasının önlenmesi
- İvmeölçer sensörü yardımıyla akıllı telefonun x, y ve z eksenindeki hareketleri bilinir. Aşağıdaki Şekil 1'de bir akıllı telefonun hareket yönleri gösterilmiştir. Bu sensör yardımıyla her üç eksenindeki hızlanma değeri elde edilir. Yani hızdaki değişim ya da bir diğer ifadeyle zamana bölünen hızın ölçümü yapılır.



Şekil 1. İvmeölçer ile Akıllı Telefon Hareket Yönleri
Özel bir ortam oluşturmaya ya da özel bir cihaz geliştirmeye gerek kalmadan her kullanıcıda bulunan bir akıllı telefon ile yürüyüş tanınmanın gerçekleştirilmesi diğer yöntemlere kıyasla avantajlıdır. Bu özelliği nedeniyle veri toplamak daha kolay ve ucuzdur. Bu özellik akıllı telefon ile çeşitli kimlik tanıma çalışmaları geliştirilmesine (Y. Li *et al.* 2018, Shen *et al.* 2017, Shuwandy *et al.* 2019) ve yürüyüş analizi çalışmaları (Cola *et al.* 2017, B.

Sun *et al.* 2014, Zou *et al.* 2017) geliştirilmesine yardımcı olmuştur. Ayrıca bu yöntem ile elde edilen başarı oranları daha yüksek olduğu önceki başlıkta gösterilmiştir. Tüm bunların yanı sıra yürüyüş analizi ile hastalıkların tespiti yapılabilmektedir (Ji *et al.* 2019, Khera and Kumar 2020, Suriani *et al.* 2020). Bu durum yürüyüş analizi çalışmalarının önemini göstermesinin yanı sıra yürüyüşe ait verilerin ne kadar kolay elde edildiği ve analizler sonucu başarının ne kadar yüksek olmasının da önemini ortaya çıkarmaktadır. Hemen hemen herkeste bir akıllı telefonun olduğu düşünüldüğünde bu cihazın düşük maliyetli ve taşınabilir olması özellikleri ile birlikte yürüyüş tanımda önemli bir avantajı vardır. Buradaki çalışmada amaç akıllı telefon içinde yer alan ivmeölçer sensörü verileri kullanılarak basit ve etkili bir yöntem ile yürüyüşe dayalı insan tanımlama gerçekleştirmektir. Bunun için akıllı telefon bir kemer aracılığıyla deneklerin beline takılacak ve geliştirilen yazılım ile veriler kablosuz olarak elde edilecektir. Bu çalışmanın anlaşılması ve uygulanması kolay olup düşük maliyetlidir.

4. Özellik Çıkarma

4.1. Yerel İkili Desen

Yerel İkili Desen (Local Binary Pattern-LBP) bir görüntüye ait piksellerin her birini komşu pikseller ile karşılaştırıp sonucu ikili bir sayı olarak etiketleyen bir algoritmadır. Öznitelik çıkarma algoritması olarak da bilinir ve çok verimli bir algoritmadır. Çoğunlukla görüntü işlemeye dayalı uygulamalarda kullanılıyor olsa da çok farklı uygulamalarda kullanılmaktadır. Merkez pikselin komşu pikseller için eşik olarak kullanılması mantığına dayanır ve 3x3'lük bir blokta çalışır. Bir piksele ait LBP kodu, her pikselin merkez pikselden büyük olup olmadığına göre karşılaştırılması sonucu oluşturulan ikilik tabandaki bir değerdir. Bu koda ait matematiksel ifade aşağıdaki Denklem 1 ve 2'de verilmiştir.

$$LBP(x_c) = \sum_{i=0}^{P-1} s(x_i - x_c)2^i \quad (1)$$


$$s(a) = \begin{cases} 1, & \text{if } a > 0 \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

P : Komşu piksel sayısı

n_i : i numaralı komşu piksel

c : Merkez piksel

Aşağıdaki Şekil 2'de verilen çizelgede 3x3'lük bir blok için bu hesaplamasının nasıl yapıldığını göstermektedir. Ortadaki 11 sayısı öncelikle sol üst köşede yer alan komşu 10 ile karşılaştırılır ve 11'den küçük olduğu için 0 yazılır. Sonrasında sağ tarafa doğru işlem devam ettirilir ve 6 sayısı 11 sayısından küçük olduğu için 0 ve 23 sayısı 11'den büyük olduğu için 1 yazılır. Bu işlem 11 sayısının tüm komşularına uygulanır ve hemen yandaki çizelge elde edilir. Bu çizelgede elde edilen 0 ve 1'ler sol üst köşeden başlanarak yazılır ve 2'lik tabandan 10'luk tabana dönüştürülür.

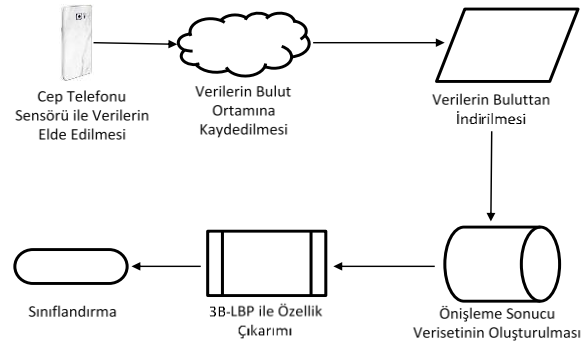


Şekil 2. Örnek LBP Kodlama

Bu algoritmanın bir öznitelik vektörüne dönüştürülmesi sonucu sınıflandırma algoritmaları ile işlenebilir. LPB kodu 0 ile 255 arasında bir değer olmaktadır. 256 sütunlu bir çizelge içinde her bir kodun tekrarı için bu değer bir arttırılır.

4.2. Üç Boyutlu Yerel İkili Desen ile Öznitelik Çıkarma

Buradaki çalışmada ise 3B-LBP yöntemi geliştirilerek sunulmuştur. Bu yöntem basit olmasının yanı sıra bilişsel ve hafif bir yöntemdir. Bu yöntem ivmeölçer sensöründen verilerin elde edilmesi, üç boyutlu yerel ikili desen ile öznitelik çıkarma ve sınıflandırma aşamalarından oluşur. Yöntemin daha iyi anlaşılabilmesi için grafik ile açıklaması Şekil 3'te verilmiştir.



Şekil 3. 3B-LBP Yöntemi ile İvmeölçer Verilerinin Sınıflandırma Özeti

Üç boyutlu yerel ikili desen (3B-LBP) yöntemi ile öznelik çıkarımının detayları psueo kod olarak aşağıda adım adım verilmiştir.

- **Adım 1:** Cep telefonu ile elde edilen kişilerin yürüme ivmeölçer verilerini bulut ortamına yükle
- **Adım 2:** Bulut ortamındaki verileri bilgisayar ortamına indir
- **Adım 3:** Verileri X Koordinatı, Y Koordinatı, Z Koordinatı ve Kişi ID olacak şekilde dört sütunlu bir yapıya dönüştür.
- **Adım 4:** Bir kişiye ait verileri 1000 kayıtlı parçalara böl
- **Adım 5:** Her 1000 kayıtlı veriye 3B-LBP öznelik çıkarma yöntemini uygula

- **Adım 5.1:** Verilerin ilk dokuz tanesini bir vektör olarak al

v_1	v_2	v_3	v_4	center	v_5	v_6	v_7	v_8
-------	-------	-------	-------	--------	-------	-------	-------	-------

Şekil 4. Dokuz boyutlu bloğun gösterimi

- **Adım 5.2** center değerini, diğer değerler ve işaret işlevini birlikte kullanarak bitleri çıkarın. Signum fonksiyonunun matematiksel tanımı Denklem 1’de gösterilmiştir. Burada o and d signum fonksiyonunun giriş değerleridir. Denklem 3 ve 4’te ise bu çalışma için, v_i değeri o gösterilirken center değeri d ile gösterilmektedir.

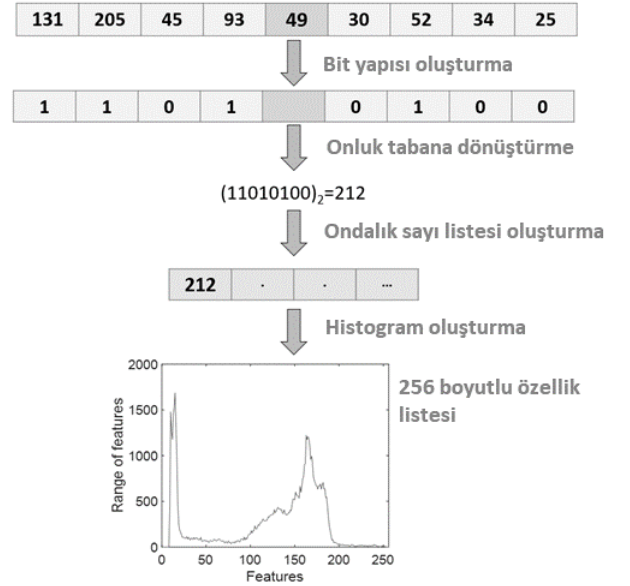
$$sgnm(o, d) = \begin{cases} 0, & o < d \\ 1, & o \geq d \end{cases} \quad (3)$$

$$bit_i = sgnm(v_i, center), i = 1, 2, \dots, 8 \quad (4)$$

- **Adım 5.3:** Sadece 0 ve 1’lerden oluşan 2’lik tabandaki sayıyı 10’luk tabana dönüştür. Bunun için aşağıdaki Denklem 5 kullanılır.

$$dcv = \sum_{t=1}^8 bit_t * 2^{8-t} \quad (5)$$

- **Adım 5.4:** Elde edilen ondalık sayıyı bir listeye yaz.
- **Adım 5.5:** Bir sonraki dokuz verilik vektörü oluştur ve Adım 5.2’ye git.
- **Adım 5.6:** Ondalık sayı listesinin histogramını oluştur. Adım 5’teki tüm işlemlerin nasıl yapılacağı aşağıdaki şekilde gösterilmiştir.



Şekil 5. Adım 5 özet

- **Adım 6:** Adım 5’teki işlemleri Y ve Z koordinat verilerine de uygula
- **Adım 7:** Çıkarılan öznelik dosyalarının tümünü alt alta birleştir
- **Adım 8:** 10-katlı çapraz doğrulama kullanarak verileri sınıflandırma işlemine tabi tut.

4.3. Topluluk Sınıflandırma Algoritmaları

Topluluk sınıflandırıcılar (Ensemble classification) birçok zayıf öğrenme algoritmasını birleştirerek kullanarak nihai sınıflandırma oluşturan çok popüler bir çerçevedir. Zayıf sınıflandırıcıların hem doğruluğunu hem de kararlılığını geliştirmeyi amaçlayarak onların tek başına ortaya çıkarttığı performanstan daha iyi sonuç çıkarır (Rokach 2010). Torbalama (bagging) (Breiman 1999) ve rastgele orman (random forest) (Breiman 2001) topluluk sınıflandırmasının iki önemli örneğidir ve karar ağaçlarına odaklanmış olup performansı iyileştirmeyi amaçlamaktadır. Bagging (bootstrap aggregation) yönteminde her alt uzay eğitim veriseti ile aynı boyuta sahiptir. Bu nedenle içerisinde bir örnek birden fazla kez tekrar edebilir (asıl verisetinin yaklaşık %63’ü). Böylece öğrenme performansını arttıran çeşitli sınıflandırıcılar elde edilir (Efron and Tibshirani 1994). Boosting (güçlendirme) bir başka topluluk sınıflandırıcı algoritma olup hem kategorik hem de sürekli sürekli değişkenler için kullanılabilir. İlgisiz ve önemsiz bağımsız değişkenler modelden otomatik çıkarılır. Ayrıca eksik değerler ile aykırı değerlerin varlığı herhangi bir soruna neden olmaz. Boosting, bootstrap tabanlı bir yöntem olup tüm

örnekler rastgele değiştirilerek modellemede kullanılır. Böylece ezberleme oluşması engellenmiş olur (Cherkassky and Mulier 2007, Schapire et al. 1998). Bir örneğin önceden sınıflandırılmış olan k tane örneğin yakınlığı dikkate alınarak sınıflandırılması k-en yakın komşu (KNN) algoritması ile olur. İki örnek arasındaki mesafe öklid mesafesidir. KNN yöntemi basit ve hızlı olmasını yanı sıra gürültülü verilere karşı da dayanıklı olup başarılı sonuçlar elde edebilmektedir (Cover and Hart 1967). Alt uzay KNN, veri setindeki belirli sayıda özneliğin alt kümelerini rasgele seçer ve sınıflandırır (Ho 1998). Veri kümesindeki tüm örnekler, seçilen alt uzaylara göre değerlendirilir ve en yakın k komşu, bu alt uzaylardaki mesafe değeri kullanılarak bulunur. Her rastgele alt uzay seçildiğinde, yeni bir en yakın komşu kümesi hesaplanır. Her bir alt uzaydaki en yakın k komşu, test örneklerindeki sınıf etiketlerinin en yüksek oylarına sahip sınıf değeri ile belirlenir. Farklı alt uzaylarda en yakın k komşuluk değerine sahipse, aynı eğitim örneği birden fazla etikete sahip olabilir. Bu yöntem rastgele öznelik alt kümeleri kullandığından, göreceli olarak çok sayıda özneliğe sahip problemler için daha iyi sonuçlar sağlayabilir (Karasu ve Başkan 2016). Bu yöntem buradaki çalışmada çok sayıda özneliğe sahip veri seti kullanıldığı için tercih edilmektedir.

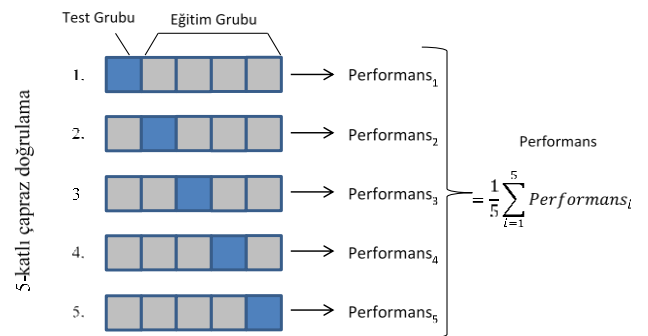
4.4. Eğitim ve Test Verilerin Ayrıştırılması

Çapraz doğrulama (cross-validation) makine öğrenmesi algoritmalarında modelin eğitim amaçlı kullanmadığı verilerdeki performansını olabildiğince objektif ve doğru bir şekilde değerlendirmek amacıyla kullanılan yeniden örnekleme yöntemidir. Makine öğrenmesine veriler sunulmadan önce verilerin bir kısmı eğitim için kalan bir kısmı da test için ayrıştırılır. Böylece eğitim gerçekleştikten sonra eğitimin başarısı algoritmanın daha önce hiç kullanmadığı ve görmediği veriler üzerinde test edilerek ölçülür. Genel bir yaklaşım olarak verilerin 1/3'ü test ve 2/3'ü eğitim amaçlı olarak ayrıştırılır. Bu ayırmada rastgele seçim yöntemi kullanılır. Fakat bu şekilde verileri ayrıştırma işlemi uygulandığında bir kısım veriler öğrenmeye katılmayacağından eğitimin başarısı düşük çıkabilir. Ya da tam tersi olarak öğrenmeye katılan veriler anlaşılması kolay veriler olurken test için kullanılan veriler daha

karmaşık olabilir. Bu tür durumlar öğrenmenin başarısını doğrudan etkileyecektir. Bunun yerine bütün verilerin eğitim amaçlı kullanılması yaklaşımı daha doğru olacaktır. Çapraz doğrulama yöntemi tüm örnekleri hem test hem de eğitim amaçlı kullanan bir tekniktir (Bengio and Grandvalet 2004). Bu yöntem verimlilik açısından tercih edilebilir bir yöntemdir (Efron 2004, Stone 1977). Bu yöntemin çalışma algoritması aşağıdaki gibidir.

- **Adım 1.** Verisetini rastgele karıştır
- **Adım 2.** Verisetini k adet gruba ayır
- **Adım 3.**
 - **Adım 3.1.** k adet gruptan bir tanesini test için kullanılacak grup olarak belirle
 - **Adım 3.2.** Kalan tüm diğer grupları eğitim için kullanılacak grup olarak belirle
 - **Adım 3.3.** Eğitim grubu makine öğrenmesi algoritmaları ile eğit
 - **Adım 3.4.** Test grubu üzerinde öğrenme başarısı test et
 - **Adım 3.5.** Öğrenme başarısı ölçütleri kayıt altına alınır ve diğer tüm gruplar bitene kadar Adım 3.1'e git
- **Adım 4.** k adet ortaya çıkan test işleminde başarı sonuçlarının ortalamasını al

Bu yöntemle ait algoritmanın adımları yukarıda verilmiştir. Bu algoritmanın daha iyi anlaşılması adına örnek olarak 5-katlı çapraz doğrulama algoritmasının görsel olarak anlatımı aşağıdaki Şekil 6'da verilmiştir.



Şekil 6. Çapraz Doğrulama Algoritması

Çapraz doğrulama yöntemi kullanılarak verilerin ayrıştırılmasında çoğunlukla 10-katlı çapraz doğrulama kullanılır (Allix et al. 2014). Çapraz doğrulama katsayısı daha fazla arttırılabilir fakat bu durum daha fazla hesaplama maliyeti anlamına geleceği unutulmamalıdır. Bu nedenle ne kadar fazla

çapraz doğrulama sayısı olursa o kadar çok modelin eğitilmesi gerektiği dikkate alınmalıdır. Fakat çapraz doğrulama katsayısının büyümesiyle daha yüksek başarı sonuçları elde edildiği söylenemez (Zhang *et al.* 2015).

4.5. Başarı Ölçütleri

Sınıflandırma algoritmaları bir kategorik değişkene bağlı olarak verilerin hangi kategoriye ait olduklarını bulmaya çalışır. Bu işlemin başarısını değerlendirmek için yaygın olarak kullanılan hata analizleri vardır. Bunun için en yaygın kullanılan başarı ölçütü karışıklık matrisidir. Aşağıdaki Şekil 7’de örnek bir karışıklık matrisi verilmiştir.

		Öngörülen Sınıf	
		Sınıf=1	Sınıf=0
Doğru Sınıf	Sınıf=1	TP	FN
	Sınıf=0	FP	TN

Şekil 7. Hata Matrisi

Sol üst köşeden başlayıp sağ alt köşeye giden köşegende yer alan değerlerin yüksek olması başarının yüksek olması anlamına gelirken diğer noktalarda yer alan değerler başarıyı düşürecektir. Hata matrisi olarak da adlandırılan bu çizelgede kısaltmalar ile ilgili açıklamalar aşağıda verilmiştir.

- Doğruya doğru demek (TP (True Positive))- Doğru Tahmin
- Yanlışta yanlış demek (TN (True Negative))- Doğru Tahmin
- Yanlışta doğru demek (FP (False Positive))- Yanlış Tahmin
- Doğruya yanlış demek (FN (False Negative))- Yanlış Tahmin

Buradaki hata matrisinde verilerden başka başarı ölçütleri hesaplanabilir. En yaygın kullanılan başarı ölçütleri arasında doğruluk oranı ve yanlışlık oranı gelmektedir. Aşağıdaki Denklem 6 ve 7’de bu hesaplama ait formüller verilmiştir.

$$\text{Doğruluk oranı} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$\text{Hata oranı} = \frac{FP + FN}{P + TN + FP + FN} \quad (7)$$

Doğruluk oranı doğru sınıflandırılmış örnek sayısının toplam örnek sayısına bölünmesi ile bulunurken hata oranı yanlış sınıflandırılmış örnek sayısının toplam örnek sayısına bölünmesi ile bulunur. Bunların yanı sıra yine kullanılan bir başka başarı ölçütü olarak kesinlik ve duyarlılık değerleri vardır. Bunlar da aşağıdaki denklemlerde verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (8)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (9)$$

Kesinlik değeri doğru sınıflandırılmış ve gerçekte de doğru olan değerlerin toplam doğru diye sınıflandırılan değerlere bölümüdür. Duyarlılık ise gerçekte doğru olan ve doğru sınıflandırılmış değerlerin doğruyu yanlış olarak tahmin edilen değerler ile olan toplamına bölümüdür. Fakat bu iki ölçüt tek başlarına anlamlı bir karşılaştırma sağlamakta yetersiz olmasından dolayı her iki ölçütü beraber değerlendiren F-ölçütü değeri vardır. Bu değer kesinlik ve duyarlılığın harmonik ortalaması olup aşağıdaki Denklem 10’da verilmiştir.

$$F - \text{ölçütü} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (10)$$

5. Materyal ve Yöntem

5.1. Verilerin Toplanması

Çalışma içerisinde %84’ü erkek ve %16’sı kadın olmak üzere toplam 50 kişiden yararlanılmıştır. Deneklere öncelikle çalışma hakkında bilgi verilmiş ve Kırşehir Ahi Evran Üniversitesi Fen ve Mühendislik Bilimleri Bilimsel Araştırma ve Yayın Etiği Kurulunun 02.07.2020 tarihli ve 2020/1 sayılı kararı gösterilmiştir. Etik kurul dosyası çalışmanın içerisinde Ek 1 olarak da verilmiştir. Deneklere bilgilendirilmiş onam formu imzalatıldıktan sonra araştırmacı tarafından oluşturulan kemer ve kemere monte edilen cep telefonu tutacağı sistemi gösterilmiştir. Akıllı telefonların kemere takılan bir kılıfa yerleştirilmesi (Derawi *et al.* 2010, Nickel *et al.* 2011) ya da bacakların farklı noktalarına

yerleştirilmesi (Zhang *et al.* 2014) ile farklı çalışmalar varsa da burada bu çalışmalardan daha yüksek başarı oranı elde etmek amaçlanmıştır. Bunun için akıllı telefon sensörlerinin yürüme esnasında daha çok sarsıntı hassasiyeti elde etmesi amacıyla bele takılan kemer ve oradan uzatılmış bir tutacak tercih edilmiştir. Böylece yürüme bozuklukları gibi daha hassas tahminlerin de yapılabileceği düşünülmektedir. Kemer takmaları gerektiği ve nasıl işlemler yapılacağı, hangi verilerin toplanacağı ifade edilmiştir. İki denek verilerin toplanma şekline karşı çıktığı için çalışmaya katılmak istemediklerini belirterek geri çekilmiştir. Bu kişilerin yerine yeni denekler bulunmuş sayı 50'ye tamamlanmıştır. Deneklere takılan kemerin görüntüsü aşağıdaki Şekil 8'de gösterilmiştir.



Şekil 8. Kemer Takılı Örnek Bir Deneğin Yürüyüşü

Normal bir kemere hemen hemen herkesin beline takılabilmesi için öncelikle fazladan delikler delinmiştir. Ardından araçlar için olan cep telefonu tutacağına cama takılan bölmesi ek deri parçaları yardımıyla kemere perçinlenmiştir. Cep telefonu tutacağına gevşek olmaması, yalnızca kişinin beli ile sallanabilmesi için sıkı bir şekilde takılmasına özen gösterilmiştir. Aşağıdaki Şekil 9'da kemerin fotoğrafı gösterilmiştir.



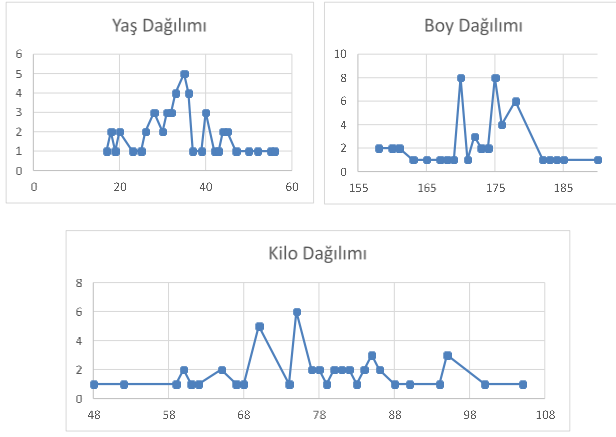
Şekil 9. Kemer ve Cep Telefonu Tutacağı

Toplam bir gidiş uzunluğu 80 metre olan yan yana iki koridorda denekler yürütülmüştür. Deneklerin yaşları 17 ile 56 arasında değişmekte olup ortalama 34 yaşlarındadırlar. 158 cm ile 190 cm arasında değişen boylarda olup ortalama 172 cm boyunda olan deneklerin ağırlıkları 48 kg ile 105 kg arasında değişmektedir. Deneklere ait bilgiler aşağıdaki Çizelge 1'de verilmiştir.


Çizelge 1. Deneklere ait bilgiler

Cinsiyet	Sayısı	Yaş	Boy	Kilo
		(Min-Maks-Ort)	(Min-Maks-Ort)	(Min-Maks-Ort)
Erkek	42	17-56 (34,45)	160-190 (174,45)	59-105 (78,97)
Kadın	8	28-42 (33,50)	158-170 (162,50)	48-82 (67,37)
Genel	50	17-56 (34,30)	158-190 (172,54)	48-105 (77,12)

Deneklere ait yaş, boy ve kilo verileri farklı değerlere sahiptir. Çizelge 1 içerisinde verilen minimum, maksimum ve ortalama değerler verilerin nasıl dağıldığını kısmen anlatmaktadır. Her bir kişiye ait yaş, boy ve kilo verilerin nasıl dağıldığı aşağıdaki Şekil 10'da da gösterilmiştir. Şekil 10 incelendiğinde yaşların ağırlıklı olarak 20 ile 40 arasında, boyların ise 165 ile 175 aralığında kiloların ise 60 ile 85 aralığında dağıldığı görülmektedir.



Şekil 10. Deneklerin Yaş, Boy ve Kilo Verilerinin Dağılımı
Denekler L şeklindeki 80 metre uzunluğuna sahip bir koridorda yürümüşlerdir. Bu koridorun başlangıç noktasından bitiş noktasına kadar bir kez yürüdükten sonra bitiş noktasından tekrar başlayarak başlangıç noktasına kadar ikinci kez yürümüşlerdir. Yine başlangıç noktasından başlamak üzere koridorun bitiş noktasına kadar üçüncü kez yürüyerek bir kişi için veri toplama sonlandırılmıştır. Her yürüyüş sırasında cep telefonu uygulaması durdurulup veriler bulut ortamına gönderilmiş ve tekrar uygulamanın başlatılması ile yürüyüş başlatılmıştır. Koridor sonunda deneklerin dönüşü yapması sırasında toplanacak ivmeölçer verilerinin etkilenmemesi amacıyla bu yöntem tercih edilmiştir. Aşağıdaki Şekil 11’de yürüme koridorunun krokisi verilmiştir.



Şekil 11. Yürüme Koridorunun Krokisi

Koridorun zemini parlak fayans ile kaplıdır. Pürüzsüz yapısı nedeniyle deneklerin rahatça yürüyebileceği bir ortama sahiptir. Yerde taş kırıntısı veya denekleri

rahatsız edecek başka unsurlar olmaması için öncelikle bir temizlik yapılmış ve ardından yürüme işlemine başlanmıştır. Aşağıdaki Şekil 12’de yürüme alanlarının fotoğrafları gösterilmiştir.




Şekil 12. Koridorların Fotoğraf Görüntüsü

5.2. Verilerin Analizi

Yürüme verileri Android tabanlı bir cep telefonuna yazılmış olan bir uygulama aracılığıyla toplanmıştır. Veriler web servis aracılığıyla internete bağlı bir sunucuya gönderilmiştir. Tüm veri toplama süreçleri tamamlanınca veriler buradan indirilmiş ön işleme tabi tutulmuştur. Veriler dört sütunlu bir yapıya sahiptir. İlk sütun ivmeölçer sensörünün X koordinatındaki değerini, ikinci sütun Y koordinatındaki değerini ve üçüncü sütunda Z koordinatındaki değerler gösterilmektedir. Son sütunda ise her kişinin tekil bir ID değeri vardır. Her bir koordinat değeri 3B-LBP yöntemi kullanılarak 256 sütunlu bir öznitelik vektörüne dönüştürülmüştür. Toplam üç eksen için 768 sütunlu bir öznitelik vektörü oluşturulmuştur. Matlab 2019b programı kullanılarak yapılan bu analizler sonucu veriseti ön işleme aşamaları tamamlanmış ve

sınıflandırma algoritmalarına sunulacak hale dönüştürülmüştür.

Verilerin önışleme aşamasında örnek olarak rastgele seçilen beş farklı kişinin yürüme verileri analiz edilerek bir grafiğe dönüştürülmüştür. Aşağıdaki Şekil 13 incelendiğinde her bir kişinin yürüme verileri her üç eksen için de farklılık gösterdiği görülmektedir. Çalışma içerisinde hiçbir yerde deneklerin kişi bilgileri kullanılmamış olup her yerde kişiyi ifade eden tekil ID değeri verilmiştir. 5, 9, 21, 37 ve 45 ID numaralı kişilere ait verilerde her ekseninde adımlar ayırt edilebilmektedir. Her bir adımın deseni dikkatle incelendiğinde kişiden kişiye bariz bir şekilde farklılık gösterdiği rahatlıkla söylenebilir. 3B-LBP yöntemi bu verilerin birbiri ile ilişkisini ortaya çıkarmada başarılı bir öznetelik çıkarma yöntemi olmuştur.

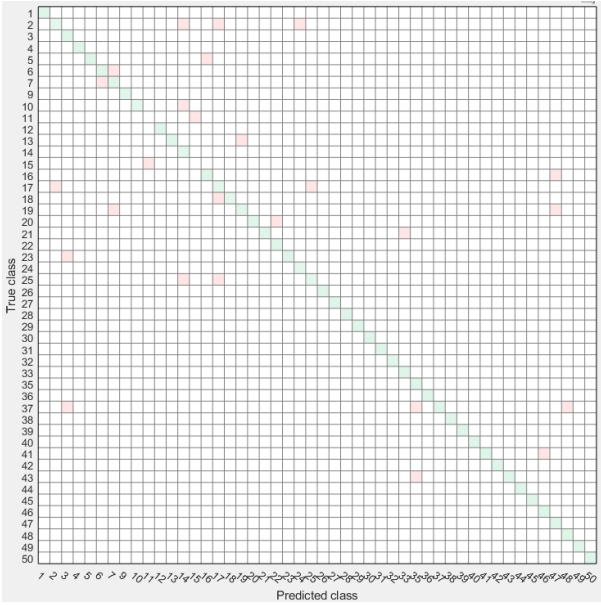


Şekil 13. Rastgele Seçilen Beş Kişinin Yürüme Verileri Veriler 10-katlı çapraz doğrulama yöntemi ile eğitim ve test verisi olarak ayrıştırılmıştır. Böylelikle verilerin tümü eğitim amaçlı kullanılmış ve hem daha iyi bir öğrenme sağlanmış hem de daha yüksek bir başarı oranı elde edilmiştir. Matlab programı içerisinde yer alan sınıflandırma aracı kullanılarak verilerin sınıflandırmaya uygun tüm algoritmalar ile eğitilmesi sağlanmıştır. Aşağıdaki Çizelge 2'de her bir sınıflandırma algoritmasının sonuçları gösterilmiştir.

Çizelge 2. Kişi Tanıma Sınıflandırma Sonuçları

Sınıflandırma Grubu	Sınıflandırma Algoritması	Sınıflandırma Başarısı (%)
Tree	Fine Tree	62,3
	Medium Tree	30,6
	Coarse Tree	11,1
Naive Bayes	Kernel Naive Bayes	94,3
SVM	Linear SVM	93,3
	Quadratic SVM	93,0
	Qubic SVM	90,4
	Fine Gaussian SVM	3,1
	Medium Gaussian SVM	75,5
	Coarse Gaussian SVM	23,2
	KNN	Fine KNN
Medium KNN		50,6
Coarse KNN		27,2
Cosine KNN		87,8
Cubic KNN		44,7
Weighted KNN		54,6
Ensemble	Boosted Trees	60,8
	Bagged Trees	80,6
	Subspace Discriminant	95,8
	Subspace KNN	97,2
	RUSBoosted Trees	20,7

Çizelge 1 incelendiğinde en yüksek sınıflandırma başarısının Subspace KNN yöntemi ile elde edildiği görülecektir. Subspace KNN yöntemi toplam 51,95 saniye içerisinde %97,2 oranında sınıflandırma başarısı ile elde etmiştir. 991 verinin yalnızca 28 tanesi yanlış sınıflandırılmış fakat 963 tanesi doğru sınıflandırılmıştır. Aşağıdaki Şekil 14'te Subspace KNN yöntemi ile elde edilen karışıklık matrisi verilmiştir. Matrisin 50x50 boyutlarında olması nedeniyle içerisindeki sayılar gösterilememiştir.



Şekil 14. Karışıklık Matrisi

Çalışmanın başarı ölçütleri arasında F-ölçütü, kesinlik ve duyarlık hesaplamaları da yapılmıştır. Matlab içerisinde daha önceki başlıklarda anlatılan formüllerden yararlanılarak yapılan hesaplamada F-ölçütü 0,9541 bulunurken, kesinlik değeri 0,9152 ve duyarlılık değeri ise 0,9158 bulunmuştur. Bu değerler aşağıdaki Çizelge 3 içinde gösterilmiştir.

Çizelge 3. Kişi Tanıma Başarı Ölçütleri

Başarı Ölçütü	Değeri
Doğruluk Oranı (ACC)	0,9720
Hata Oranı (EER)	0,0280
Kesinlik (Precision)	0,9152
Duyarlık (Recall)	0,9158
F-ölçütü	0,9541

Çalışma içerisinde 42 erkek ve 8 kadın denek bulunmaktadır. Cinsiyet dağılımları her ne kadar erkek ağırlıklı olsa dahi çalışmada yürüyüş deseninden cinsiyet tahmini de yapılmak istenmiştir. Diğer sınıflandırma algoritmalarına kıyasla yine en yüksek başarı oranı Subspace KNN içinde %99,7 olarak elde edilmiştir. Aşağıdaki Çizelge 4 içinde cinsiyet tanıma için farklı algoritma sonuçları gösterilmiştir. Kişi tanımaya kıyasla çok daha yüksek başarılı sınıflandırma yapıldığı görülmektedir. Bu durum cinsiyetin yürüyüş deseninden daha belirgin bir şekilde ayrışabildiğini göstermektedir.

Çizelge 4. Cinsiyet Tanıma Sınıflandırma Sonuçları

Sınıflandırma Grubu	Sınıflandırma Algoritması	Sınıflandırma Başarısı (%)
Tree	Fine Tree	90,8
	Medium Tree	91,5
	Coarse Tree	90,6
Naive Bayes	Kernel Naive Bayes	51,8
	Linear SVM	95,0
SVM	Quadratic SVM	96,1
	Qubic SVM	96,2
	Fine Gaussian SVM	81,2
	Medium Gaussian SVM	93,8
	Coarse Gaussian SVM	81,2
	Fine KNN	90,6
	Medium KNN	89,6
KNN	Coarse KNN	81,2
	Cosine KNN	97,8
	Cubic KNN	88,1
	Weighted KNN	89,6
	Boosted Trees	96,2
Ensemble	Bagged Trees	92,0
	Subspace Discriminant	95,7
	Subspace KNN	99,7
	RUSBoosted Trees	97,6

Cinsiyet tanıma analizinde 0,9950 F-ölçütü bulunmuş ve 0,003 hata oranı tespit edilmiştir. Çok yüksek bir başarı oranı ile cinsiyet ayrımı yapılabildiği gösterilmiştir.

Çizelge 5. Cinsiyet Tanıma Başarı Ölçütleri

Başarı Ölçütü	Değeri
Doğruluk Oranı (ACC)	0,997
Hata Oranı (EER)	0,003
Kesinlik (Precision)	0,9961
Duyarlık (Recall)	0,9940
F-Ölçütü	0,9950

6. Tartışma ve Sonuç

6.1. Tartışma

İvmeölçer tabanlı yürüyüş tanıma güvenlik ve erişim kontrol alanlarında ortaya çıkan ve hızla gelişen bir teknolojidir. Belirli bir sabit yürüme hızına sahip yürüyüşlerde olağanüstü performansları görülebilmektedir. Yürüme hızındaki değişimler ve

olağandışı bir yürüyüş sergilenmesi durumunda sistemin başarı performansı kuşkusuz önemli bir ölçüde bozulacaktır. Buradaki çalışmada olağan bir normal yürüyüş dikkate alınmıştır. Kişilerin koşma, seri yürüme, yorgun olarak yürüme gibi farklı durumlardaki yürüyüşlerin de sisteme öğretilmesi başarı ölçütünü korumayı sağlayacaktır. Sun vd. (2018) tarafından bu durumu elimine etmek için vücudun beş farklı noktasına takılan ivmeölçer sensörlerinden elde edilen yürüme verileri farklı hızlarda örneklenmiştir. Bu şekilde %96,9 oranında başarı sınıflandırma elde etmiştir. Zeng vd. (2018) tarafından da %96,2 oranında sınıflandırma başarısına sahip bir yürüyüş tanıma çalışması yapılmıştır. Buradaki her iki çalışmada bu çalışmadaki %97,2 oranındaki başarılı sınıflandırmadan daha düşüktür. Muaaz ve Mayrhofer (2017) ise buradaki çalışmaya çok benzer bir şekilde Android işletim sistemine sahip akıllı telefonlara yönelik geliştirilen bir uygulama ile telefonun ivmeölçer verileri toplanmıştır. 35 kişinin sol cebine yerleştirilen telefon verilerinden %87 oranında başarılı sınıflandırma elde edilmiştir. Beş kişi diğer kişilerin yürüme desenini taklit etmeye çalışsa dahi başarılı olamamıştır. Frank, Mannor ve Precup (2010) ise 25 kişilik bir gruptaki uygulamasında %100 sınıflandırma başarısı elde etmiştir. Fakat bu başarı oranının test veriseti için olduğunu ifade etmiştir. Test veriseti ise rastgele seçilen %25'lik verisetinden oluşmaktadır. Buradaki çalışmadan daha yüksek bir başarı oranı elde etmesinin verisetinin özelliklerinden ya da rastgele seçilmiş olan test veri kümesinden kaynaklı olabileceği düşünülmektedir. Kwapisz vd. (2010) tarafından yapılan bir çalışmada ise yürüyen kişinin doğru kişi olup olmadığı %100 doğruluk ile bulunmuştur. Bu yüksek başarı oranının ortaya çıkmasındaki temel sebebin ikili bir sınıflandırma yapılması olduğunu düşünülmektedir. Aynı çalışma içerisinde bazı kişilerde %100'ün altında bulma başarı oranları da vardır. Zhong vd. (2015)'in çalışmasında yine akıllı telefon ivmeölçer verileri 51 kişi için kullanılmıştır. Denek sayısının buradaki çalışmaya yakın olmasına rağmen %3,88 hata oranı elde edilmiştir. Buradaki çalışmada bulunan %2,8 hata oranından daha yüksektir. Giyilebilir sensörler yardımıyla elde edilen yürüme verileri farklı

çalışmalarda kullanılmışsa (Derawi *et al.* 2010, Tao *et al.* 2012) da buradaki çalışma ile benzerliği düşük olmasından dolayı karşılaştırma yapılmamıştır. Yine benzer şekilde yürüyüş tanıma için görüntü işleme ile yapılan çalışmalar da vardır (Aqmar *et al.* 2012, Del Pozo *et al.* 2012) fakat buradaki çalışma ile benzerlikleri düşük olmasından dolayı karşılaştırma yapılmamıştır.

6.2. Sonuç

Mobil cihazlar gittikçe daha karmaşık hale gelmesinin yanı sıra birçok farklı ve güçlü sensörü de bünyesinde barındırmaya çalışmaktadır. Yeni nesil akıllı telefonlar özellikle GPS sensörleri, görüntü sensörleri (kameralar), ses sensörleri (mikrofonlar), ışık sensörleri, sıcaklık sensörleri, yön sensörleri (pusulalar) ve hızlanma sensörleri gibi birçok farklı sensörleri içermektedir. Bu sensörlerin kullanılması ile birçok farklı çalışma yapılabilmektedir. Bu çalışmalardan biri de cep telefonu ile yürüyüş deseni tanımadır. İvmeölçer tabanlı biyometrik yürüyüş, bireyleri akıllı telefonları aracılığıyla doğrulamanın göze çarpmayan bir yoludur. Bu çalışmada, akıllı telefon tabanlı yürüyüşten kimlik doğrulamasının güvenlik gücünü gerçekçi bir şekilde ölçmek amaçlanmıştır. Toplam 50 farklı denekten cep telefonu uygulaması yardımıyla ivmeölçer sensör verileri toplanmıştır. Bu veriler 3B-LBP yöntemi ile öznitelik çıkarma analizi uygulandıktan sonra sınıflandırma algoritmaları yapılmıştır. İvmeölçer sensörünün X, Y ve Z koordinatına ait verilerden 768 öznitelik çıkarımı yapılmıştır. Subspace KNN algoritması ile %96,2 oranında başarılı kişi tanıma sonucu elde edilmiştir. Bu yöntemin farklı çalışmalarda da düşük hata oranına sahip olması burada bu yöntemin etkinliğini açıklamaktadır (Gul *et al.* 2018, García-Pedrajas and Ortiz-Boyer 2009). Bu durum cep telefonu yardımıyla kişilerin yürüyüş deseninin başarılı bir şekilde tanınabileceğini göstermektedir.

6.3. Öneriler

Bu çalışmada elde edilen yüksek başarı yürüyüş deseninden yürüme bozukluklarının da belirlenebileceğinin işaretidir. Maliyeti yüksek cihazlar yerine herkeste bulunan bir akıllı telefon uygulaması yardımıyla bu tür analizlerin yapılması kuşkusuz

önemlidir. İleriki çalışmalarda birden fazla cep telefonunun kişinin farklı vücut noktalarına yerleştirilmesiyle elde edilecek verilerle analizler yapılabilir. Özellikle tıp alanında yararlanılabilecek farklı uygulamalar yapılabileceği düşünülmektedir. Buradaki uygulamanın benzeri farklı kişi sayısında ve birden fazla cep telefonu kullanılarak yapılabilir ve sonuçlar karşılaştırılabilir.

7. Kaynaklar

- Addlesee, M.D., Jones, A., Livesey, F. and Samaria, F., 1997. The ORL active floor [sensor system]. *IEEE Personal Communications*, **4(5)**, 35-41.
- Allix, K., Bissyandé, T. F., Jérôme, Q., Klein, J., State, R. and Le Traon, Y., 2014. Large-scale machine learning-based malware detection: confronting the "10-fold cross validation" scheme with reality. Paper presented at the Proceedings of the 4th ACM conference on Data and application security and privacy.
- Annadhorai, A., Guenterberg, E., Barnes, J., Haraga, K. and Jafari, R., 2008. Human identification by gait analysis. Paper presented at the Proceedings of the 2nd International Workshop on Systems and Networking Support for Health Care and Assisted Living Environments.
- Aqmar, M. R., Shinoda, K. and Furui, S., 2012. Robust gait-based person identification against walking speed variations. *IEICE TRANSACTIONS on Information and Systems*, **95(2)**, 668-676.
- Arora, P., Hanmandlu, M. and Srivastava, S., 2015. Gait based authentication using gait information image features. *Pattern Recognition Letters*, **68**, 336-342.
- Balasubramanian, C. K., Bowden, M. G., Neptune, R. R. and Kautz, S. A., 2007. Relationship between step length asymmetry and walking performance in subjects with chronic hemiparesis. *Archives of physical medicine and rehabilitation*, **88(1)**, 43-49.
- Barclay, C. D., Cutting, J. E. and Kozlowski, L. T., 1978. Temporal and spatial factors in gait perception that influence gender recognition. *Perception & psychophysics*, **23(2)**, 145-152.
- Barra, P., Bisogni, C., Nappi, M., Freire-Obregón, D. and Castrillón-Santana, M., 2019. Gait analysis for gender classification in forensics. Paper presented at the International Conference on Dependability in Sensor, Cloud, and Big Data Systems and Applications.
- BenAbdelkader, C., Cutler, R. and Davis, L., 2002. Motion-based recognition of people in eigengait space. Paper presented at the Proceedings of Fifth IEEE international conference on automatic face gesture recognition.
- Bengio, Y. and Grandvalet, Y., 2004. No unbiased estimator of the variance of k-fold cross-validation. *Journal of machine learning research*, **5**(Sep), 1089-1105.
- Bingham, G. P., Schmidt, R. C. and Rosenblum, L. D., 1995. Dynamics and the orientation of kinematic forms in visual event recognition. *Journal of Experimental Psychology: Human Perception and Performance*, **21(6)**, 1473.
- Bouchrika, I. and Nixon, M. S., 2006. People detection and recognition using gait for automated visual surveillance. 2006 IET Conference on Crime and Security, London, UK, 2006, pp. 576-581.
- Breiman, L., 1999. Pasting small votes for classification in large databases and on-line. *Machine learning*, **36(1-2)**, 85-103.
- Breiman, L., 2001. Random forests. *Machine learning*, **45(1)**, 5-32.
- Chao, H., He, Y., Zhang, J. and Feng, J., 2019. Gaitset: Regarding gait as a set for cross-view gait recognition. Paper presented at the Proceedings of the AAAI Conference on Artificial Intelligence.
- Cherkassky, V. and Mulier, F. M., 2007. Learning from data: concepts, theory, and methods: John Wiley & Sons Press, New Jersey, 30-60.
- Cola, G., Avvenuti, M. and Vecchio, A., 2017. Real-time identification using gait pattern analysis on a standalone wearable accelerometer. *The Computer Journal*, **60(8)**, 1173-1186.
- Connor, P. and Ross, A., 2018. Biometric recognition by gait: A survey of modalities and features. *Computer Vision and Image Understanding*, **167**, 1-27.
- Cover, T. and Hart, P., 1967. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, **13**, 19-17.
- Cunado, D., Nixon, M. S. and Carter, J. N., 2003. Automatic extraction and description of human gait models for recognition purposes. *Computer Vision and Image Understanding*, **90(1)**, 1-41.

- Del Pozo, G. B., Sanchez-Avila, C., De-Santos-Sierra, A. and Guerra-Casanova, J., 2012. Speed-independent gait identification for mobile devices. *International Journal of Pattern Recognition and Artificial Intelligence*, **26(08)**, 1260013.
- Derawi, M. O., Bours, P. and Holien, K., 2010. Improved cycle detection for accelerometer based gait authentication. Paper presented at the 2010 Sixth International Conference on Intelligent Information Hiding and Multimedia Signal Processing.
- Derawi, M. O., Nickel, C., Bours, P. and Busch, C. 2010. Unobtrusive user-authentication on mobile phones using biometric gait recognition. In 2010 Sixth International Conference on Intelligent Information Hiding and Multimedia Signal Processing (pp. 306-311). IEEE.
- Dewar, M. and Judge, G., 1980. Temporal asymmetry as a gait quality indicator. *Medical and Biological Engineering and Computing*, **18(5)**, 689-693.
- Efron, B., 2004. The estimation of prediction error: covariance penalties and cross-validation. *Journal of the American Statistical Association*, **99(467)**, 619-632.
- Efron, B. and Tibshirani, R. J., 1994. An introduction to the bootstrap: CRC Press, 40-80.
- El-Alfy, E.-S. and Binsaadoon, A. G., 2019. Automated gait-based gender identification using fuzzy local binary patterns with tuned parameters. *Journal of Ambient Intelligence and Humanized Computing*, **10(7)**, 2495-2504.
- Frank, J., Mannor, S. and Precup, D., 2010. Activity and gait recognition with time-delay embeddings. Paper presented at the Proceedings of the AAAI Conference on Artificial Intelligence.
- Gafurov, D., Helkala, K. and Søndrol, T., 2006. Biometric Gait Authentication Using Accelerometer Sensor *JCP*, **1(7)**, 51-59.
- Gafurov, D. and Snekenes, E., 2009. Gait recognition using wearable motion recording sensors. *EURASIP Journal on Advances in Signal Processing*, 2009, 1-16.
- García-Pedrajas, N. and Ortiz-Boyer, D. 2009. Boosting k-nearest neighbor classifier by means of input space projection. *Expert Systems with Applications*, **36(7)**, 10570-10582.
- Goffredo, M., Carter, J. N. and Nixon, M. S., 2008. Front-view gait recognition. Paper presented at the 2008 IEEE Second International Conference on Biometrics: Theory, Applications and Systems.
- Gouwanda, D. and Senanayake, S. A., 2011. Identifying gait asymmetry using gyroscopes—A cross-correlation and Normalized Symmetry Index approach. *Journal of biomechanics*, **44(5)**, 972-978.
- Gul, A., Perperoglou, A., Khan, Z., Mahmoud, O., Miftahuddin, M., Adler, W. and Lausen, B. 2018. Ensemble of a subset of k NN classifiers. *Advances in data analysis and classification*, **12(4)**, 827-840.
- Ho, T. K., 1998. Nearest neighbors in random subspaces. Paper presented at the Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR).
- Huang, B., Chen, M., Huang, P. and Xu, Y., 2007. Gait modeling for human identification. Paper presented at the Proceedings 2007 IEEE International Conference on Robotics and Automation.
- Iwashita, Y., Kurazume, R. and Stoica, A., 2014. Gait identification using invisible shadows: robustness to appearance changes. Paper presented at the 2014 Fifth International Conference on Emerging Security Technologies.
- Iwashita, Y., Stoica, A. and Kurazume, R., 2010. Person Identification using Shadow Analysis. Paper presented at the BMVC.
- Iwashita, Y., Uchino, K., Kurazume, R. and Stoica, A., 2012. Gait identification from invisible shadows. Paper presented at the Sensing Technologies for Global Health, Military Medicine, Disaster Response, and Environmental Monitoring II; and Biometric Technology for Human Identification IX.
- Ji, N., Zhou, H., Guo, K., Samuel, O. W., Huang, Z., Xu, L. and Li, G., 2019. Appropriate mother wavelets for continuous gait event detection based on time-frequency analysis for hemiplegic and healthy individuals. *Sensors*, **19(16)**, 3462.
- Johnston, A. H. and Weiss, G. M., 2015. Smartwatch-based biometric gait recognition. Paper presented at the 2015 IEEE 7th International Conference on Biometrics Theory, Applications and Systems (BTAS).

- Karasu, S. and Başkan, S., 2016. Classification of power quality disturbances by using ensemble technique. Paper presented at the 2016 24th Signal Processing and Communication Application Conference (SIU).
- Katiyar, R., Pathak, V. K. and Arya, K., 2014. Human gait recognition system based on shadow free silhouettes using truncated singular value decomposition transformation model. *International Journal of Artificial Intelligence and Soft Computing*, **4(4)**, 283-301.
- Khera, P. and Kumar, N., 2020. Role of machine learning in gait analysis: a review. *Journal of Medical Engineering & Technology*, **44(8)**, 441-467.
- Kwapisz, J. R., Weiss, G. M. and Moore, S. A., 2010. Cell phone-based biometric identification. Paper presented at the 2010 Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS).
- Lamar-León, J., García-Reyes, E. B. and Gonzalez-Diaz, R., 2012. Human Gait Identification Using Persistent Homology, Berlin, Heidelberg, 50-100.
- Lee, S., Liu, Y. and Collins, R., 2007. Shape variation-based frieze pattern for robust gait recognition. Paper presented at the 2007 IEEE Conference on Computer Vision and Pattern Recognition.
- Li, X., Makihara, Y., Xu, C., Yagi, Y. and Ren, M., 2018. Gait-based human age estimation using age group-dependent manifold learning and regression. *Multimedia tools and applications*, **77(21)**, 28333-28354.
- Li, X., Maybank, S. J., Yan, S., Tao, D. and Xu, D., 2008. Gait components and their application to gender recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, **38(2)**, 145-155.
- Li, Y., Hu, H., Zhou, G. and Deng, S., 2018. Sensor-based continuous authentication using cost-effective kernel ridge regression. *IEEE Access*, **6**, 32554-32565.
- Liu, Y., Collins, R. and Tsin, Y., 2002. Gait sequence analysis using frieze patterns. Paper presented at the European Conference on Computer Vision.
- Makihara, Y., Okumura, M., Iwama, H. and Yagi, Y., 2011. Gait-based age estimation using a whole-generation gait database. Paper presented at the 2011 International Joint Conference on Biometrics (IJCB).
- Mansouri, N., Issa, M. A. and Jemaa, Y. B., 2017. Gait features fusion for efficient automatic age classification. *IET Computer Vision*, **12(1)**, 69-75.
- Mantjarvi, J., Lindholm, M., Vildjiounaite, E., Makela, S.-M. and Ailisto, H., 2005. Identifying users of portable devices from gait pattern with accelerometers. Paper presented at the Proceedings.(ICASSP'05. IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005.
- Muaaz, M. and Mayrhofer, R., 2017. Smartphone-based gait recognition: From authentication to imitation. *IEEE Transactions on Mobile Computing*, **16(11)**, 3209-3221.
- Murray, M. P., Drought, A. B. and Kory, R. C., 1964. Walking patterns of normal men. *JBJS*, **46(2)**, 335-360.
- Nabila, M., Mohammed, A. I. and Yousra, B. J., 2017. Gait-based human age classification using a silhouette model. *IET Biometrics*, **7(2)**, 116-124.
- Nickel, C., Busch, C., Rangarajan, S. and Möbius, M. 2011. Using hidden markov models for accelerometer-based biometric gait recognition. In 2011 IEEE 7th International Colloquium on Signal Processing and its Applications (pp. 58-63). IEEE.
- Phillips, P. J., Sarkar, S., Robledo, I., Grother, P. and Bowyer, K., 2002. The gait identification challenge problem: Data sets and baseline algorithm. Paper presented at the Object recognition supported by user interaction for service robots.
- Rokach, L., 2010. Ensemble-based classifiers. *Artificial intelligence review*, **33(1-2)**, 1-39.
- Schapire, R. E., Freund, Y., Bartlett, P. and Lee, W. S., 1998. Boosting the margin: A new explanation for the effectiveness of voting methods. *The annals of statistics*, **26(5)**, 1651-1686.
- Semwal, V. B., Singha, J., Sharma, P. K., Chauhan, A. and Behera, B., 2017. An optimized feature selection technique based on incremental feature analysis for bio-metric gait data classification. *Multimedia tools and applications*, **76(22)**, 24457-24475.
- Shen, C., Li, Y., Chen, Y., Guan, X. and Maxion, R. A., 2017. Performance analysis of multi-motion sensor behavior for active smartphone authentication. *IEEE Transactions on Information Forensics and Security*, **13(1)**, 48-62.

- Shinzaki, M., Iwashita, Y., Kurazume, R. and Ogawara, K., 2015. Gait-based person identification method using shadow biometrics for robustness to changes in the walking direction. Paper presented at the 2015 IEEE Winter Conference on Applications of Computer Vision.
- Shorter, K. A., Polk, J. D., Rosengren, K. S. and Hsiao-Weckslar, E. T., 2008. A new approach to detecting asymmetries in gait. *Clinical Biomechanics*, **23(4)**, 459-467.
- Shuwandy, M. L., Zaidan, B., Zaidan, A. and Albahri, A., 2019. Sensor-based mHealth authentication for real-time remote healthcare monitoring system: A multilayer systematic review. *Journal of medical systems*, **43(2)**, 33.
- Si, W., Yang, G., Chen, X. and Jia, J., 2019. Gait identification using fractal analysis and support vector machine. *Soft Computing*, **23(19)**, 9287-9297.
- Sprager, S. and Zazula, D., 2009a. A cumulant-based method for gait identification using accelerometer data with principal component analysis and support vector machine. *WSEAS Transactions on Signal Processing*, **5(11)**, 369-378.
- Sprager, S. and Zazula, D., 2009b. Gait identification using cumulants of accelerometer data. Paper presented at the Proceedings of the 2nd WSEAS International Conference on Sensors, and Signals and Visualization, Imaging and Simulation and Materials Science.
- Stoica, A., 2010. Method for using information in human shadows and their dynamics. In: Google Patents.
- Stone, M., 1977. An asymptotic equivalence of choice of model by cross-validation and Akaike's criterion. *Journal of the Royal Statistical Society: Series B (Methodological)*, **39(1)**, 44-47.
- Sun, B., Wang, Y. and Banda, J., 2014. Gait characteristic analysis and identification based on the iPhone's accelerometer and gyrometer. *Sensors*, **14(9)**, 17037-17054.
- Sun, F., Mao, C., Fan, X. and Li, Y., 2018. Accelerometer-based speed-adaptive gait authentication method for wearable IoT devices. *IEEE Internet of Things Journal*, **6(1)**, 820-830.
- Suriani, N. S., Mustafa, M. H. and Abd Rahman, F. Y., 2020. Gait Analysis for Rehabilitation Assessment System Simulator. *Applications of Modelling and Simulation*, **4**, 290-296.
- Tao, W., Liu, T., Zheng, R. and Feng, H., 2012. Gait analysis using wearable sensors. *Sensors*, **12(2)**, 2255-2283.
- Tong, S., Fu, Y., Ling, H. and Zhang, E., 2017. Gait identification by joint spatial-temporal feature. Paper presented at the Chinese Conference on Biometric Recognition.
- Verlekar, T. T., Soares, L. D. and Correia, P. L., 2017. Shadow type identification for gait recognition using shadows. Paper presented at the 23rd Portuguese Conference on Pattern Recognition, RECPAD.
- Verlekar, T. T., Soares, L. D. and Correia, P. L., 2018. Gait recognition in the wild using shadow silhouettes. *Image and Vision Computing*, **76**, 1-13.
- Wang, L., Tan, T., Ning, H. and Hu, W., 2003. Silhouette analysis-based gait recognition for human identification. *IEEE transactions on pattern analysis and machine intelligence*, **25(12)**, 1505-1518.
- Yalabık, N., Yavuzer, G., Atalay, V. and Şen Köktaş, N., 2008. YAHTS: Yürüyüş Analizi ile Hastalık Tanıma Sistemi. Ankara, 106E035)
- Zeng, W., Chen, J., Yuan, C., Liu, F., Wang, Q. and Wang, Y., 2018. Accelerometer-based gait recognition via deterministic learning. Paper presented at the 2018 Chinese Control And Decision Conference (CCDC).
- Zhang, Y., Pan, G., Jia, K., Lu, M., Wang, Y. and Wu, Z., 2014. Accelerometer-based gait recognition by sparse representation of signature points with clusters. *IEEE transactions on cybernetics*, **45(9)**, 1864-1875.
- Zhang, H., Yang, S., Guo, L., Zhao, Y., Shao, F. and Chen, F., 2015. Comparisons of isomiR patterns and classification performance using the rank-based MANOVA and 10-fold cross-validation. *Gene*, **569(1)**, 21-26.
- Zhao, G., Liu, G., Li, H. and Pietikainen, M., 2006. 3D gait recognition using multiple cameras. Paper presented at the 7th International Conference on Automatic Face and Gesture Recognition (FGR06).
- Zhong, Y., Deng, Y. and Meltzner, G., 2015. Pace independent mobile gait biometrics. Paper presented at the 2015 IEEE 7th International Conference on Biometrics Theory, Applications and Systems (BTAS).

Zou, Q., Ni, L., Wang, Q., Li, Q. and Wang, S., 2017. Robust gait recognition by integrating inertial and RGBD sensors. *IEEE transactions on cybernetics*, **48(4)**, 1136-1150.

Zou, Q., Wang, Y., Wang, Q., Zhao, Y. and Li, Q., 2020. Deep Learning-Based Gait Recognition Using Smartphones in the Wild. *IEEE Transactions on Information Forensics and Security*, **15**, 3197-3212.