



T.C.
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI

AKILLI TELEFONLARIN İVMEÖLÇER SENSÖRÜ YARDIMIYLA YÜRÜYÜŞ DESENİ ANALİZİ

İbrahim KARSLIOĞLU

YÜKSEK LİSANS TEZİ

KIRŞEHİR / 2021



T.C.
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI

AKILLI TELEFONLARIN İVMEÖLÇER SENSÖRÜ YARDIMIYLA YÜRÜYÜŞ DESENİ ANALİZİ

İbrahim KARSLIOĞLU

YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Emrah AYDEMİR

KIRŞEHİR / 2021

Bu çalışma 13.05.2019 tarihinde ařağıdaki jüri tarafından İleri Teknolojiler Anabilim Dalı, Bilgisayar Mühendisliğı Programında yüksek lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Doç. Dr. Emrah AYDEMİR
Kırşehir Ahi Evran Üniversitesi
Mühendislik-Mimarlık Fakültesi
Bilgisayar Mühendisliğı
(Danışman)

Dr. Öğr. Üyesi Murat IŞIK
Kırşehir Ahi Evran Üniversitesi
Mühendislik-Mimarlık Fakültesi
Bilgisayar Mühendisliğı

Dr. Öğr. Üyesi Feyzi KAYSI
İstanbul Üniversitesi-Cerrahpařa
Teknik Bilimler Meslek Yüksekokulu
Kontrol-Otomasyon

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

İbrahim KARSLIOĞLU



20.04.2016 tarihli Resmî Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü Teze, Kırşehir Ahi Evran Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.



ÖNSÖZ

Yüksek lisansa başlamamda ve yüksek lisans ders ve tez yazım sürecinde kendisini tanıdığım günden bu yana gösterdiği sakin ve sabırlı hali ile her zaman bana örnek olmasının yanı sıra bir bilim adamının nasıl çalışması gerektiğini kendisinden öğrendiğim değerli danışmanım Dr. Öğr. Üyesi Emrah AYDEMİR'e teşekkür ederim. Çalışmalarım boyunca maddi manevi destekleriyle beni hiçbir zaman yalnız bırakmayan, beni bugünlere getiren aileme de sonsuz teşekkürler ederim.

Şubat, 2021

İbrahim KARSLIOĞLU

İÇİNDEKİLER

Sayfa No

TEZ BİLDİRİMİ	ii
ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vi
TABLO LİSTESİ.....	vii
SİMGE VE KISALTMA LİSTESİ	viii
ÖZET	ix
ABSTRACT	x
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	2
3. AMAÇ VE KAPSAM	4
4. ÖZELLİK ÇIKARMA	6
4.1. Yerel İkili Desen	6
4.2. Üç Boyutlu Yerel İkili Desen İle Özellik Çıkarma	7
4.3. Topluluk Sınıflandırma Algoritmaları.....	9
4.4. Eğitim ve Test Verilerin Ayrıştırılması.....	10
4.5. Başarı Ölçütleri	12
5. MATERYAL VE YÖNTEM.....	15
5.1. Verilerin Toplanması	15
5.2. Verilerin Analizi	20
6. TARTIŞMA VE SONUÇ.....	27
6.1. Tartışma	27
6.2. Sonuç	28
6.3. Öneriler	28
KAYNAKLAR.....	29

ŞEKİL LİSTESİ

	Sayfa No
Şekil 1. İvmeölçer ile Akıllı Telefon Hareket Yönleri.....	5
Şekil 2. Örnek LBP Kodlama.....	7
Şekil 3. 3B-LBP Yöntemi ile İvmeölçer Verilerinin Sınıflandırma Özeti.....	7
Şekil 4. Dokuz boyutlu bloğun gösterimi.....	8
Şekil 5. Adım 5 özeti.....	9
Şekil 6. Çapraz Doğrulama Algoritması	12
Şekil 8. Kemer Takılı Örnek Bir Deneğin Yürüyüşü.....	15
Şekil 9. Kemer ve Cep Telefonu Tutacağı	16
Şekil 10. Deneklerin Yaş, Boy ve Kilo Verilerinin Dağılımı	17
Şekil 11. Yürüme Koridorunun Krokisi	18
Şekil 12. Koridorların Fotoğraf Görüntüsü	19
Şekil 13. Rastgele Seçilen Beş Kişinin Yürüme Verileri.....	21
Şekil 14. Karışıklık Matrisi	23

TABLO LİSTESİ

	Sayfa No
Tablo 1. Deneklere ait bilgiler	16
Tablo 2. Kişi Tanıma Sınıflandırma Sonuçları	22
Tablo 3. Kişi Tanıma Başarı Ölçütleri	24
Tablo 4. Cinsiyet Tanıma Sınıflandırma Sonuçları	25
Tablo 5. Cinsiyet Tanıma Başarı Ölçütleri	26



SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
P	: Komşu piksel sayısı
n_i	: i numaralı komşu piksel
c	: Merkez piksel

Kısaltmalar	Açıklama
DVM	: Destek Vektör Makineleri
SVM	: Support Vector Machine
OA	: Osteoartrit
PCA	: Temel Bileşen Analizi
GKM	: Gauss Karşım Modeli
KNN	: K Nearest Neighborhood
DWT	: Discrete Wavelet Transform
GPL	: General Public Licence
LBP	: Local Binary Pattern
3B-LBP	: Üç Boyutlu Local Binary Pattern
TP	: True Positive
TN	: True Negative
FP	: False Positive
FN	: False Negative

ÖZET

YÜKSEK LİSANS TEZİ

AKILLI TELEFONLARIN İVMEÖLÇER SENSÖRÜ YARDIMIYLA YÜRÜYÜŞ DESENİ ANALİZİ

İbrahim KARSLIOĞLU

Kırşehir Ahi Evran Üniversitesi

Fen Bilimleri Enstitüsü

İleri Teknolojiler Anabilim Dalı

Danışman: Doç. Dr. Emrah AYDEMİR

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. Bu 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 Local Binary Pattern (LBP) yöntemi uygulanmış ve 256 özellik çıkarılmıştır. Farklı sınıflandırma algoritmaları ile testler yapılmış ve Cubic SVM ile %90 başarılı sınıflandırma elde edilmiştir. Bu yöntem ile yürüme bozukluğu tespitinde yüksek maliyetli cihazlar yerine daha ekonomik yöntemler geliştirileceği düşünülmektedir.

Şubat 2021, 47 Sayfa.

Anahtar Kelimeler: Yürüyüş Tanıma, İvmeölçer, Yürüyüş Deseni.

ABSTRACT

MASTER THESIS

GAIT ANALYSIS WITH USING ACCELEROMETER SENSOR OF SMART PHONES

İbrahim KARSLIOĞLU

**Kirsehir Ahi Evran University
Science and Engineering Institute
Advanced Technologies Department**

Supervisor: Assoc. Prof. Dr. Emrah AYDEMİR

The ability to measure human movements in sports fields is among the important issues for performance measurement and development. This situation 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 data was obtained from the accelerometer sensor with a software developed for the smartphone. Local Binary Pattern (LBP) method was applied to the data and 256 features were removed. Tests were carried out with different classification algorithms and 90% successful classification was achieved with Cubic SVM. With this method, it is thought that more economical methods will be developed instead of high-cost devices in detecting gait disorders.

February 2021, 47 Pages.

Keywords: Gait Recognition, Accelerometer, Gait Pattern.

1. GİRİŞ

Bir kişinin fizyolojik veya davranışsal özelliklerine göre otomatik olarak belirlenmesi biyometri alanının konusudur. Özellikle son zamanlarda büyük veride yaşanan artış ve yapay zekadaki 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 [1]. 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 [2]. İnsan yürüyüşü ortak hareket kalıplarına sahip olup vücudun hareket ettiği ritmik ve periyodik bir harekettir. Yani yüzlerce kas ve eklem senkronize hareketlerinden oluşur [3]. İnsanların yürüyüşünde her defasında küçük sapmalarla farklılıklar olsa dahi büyük oranda simetrik olup kişiye özeldir [4]. Kişiye özel olmasının temel nedenleri arasında adım süresi, duruş süresi ve salınım süresindeki farklılıklar [5] ile yer reaksiyon kuvveti profillerindeki farklılıklar [6] ve hareket aralığındaki farklılıklar [7] yer alır. Yürüyüş tanıma yaklaşımları modele [8, 9] ve görünüme [10, 11] 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 bölmeyle 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. LİTERATÜR TARAMASI

Lamar-León, Garcia-Reyes ve Gonzalez-Diaz [12] tarafından 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 [13-16]. Bir başka çalışmada ise 28 kişiye ait yürüme anındaki gölge görüntüleri analiz edilmiş ve en yüksek başarı oranı olarak %94,3 elde edilmiştir [17]. Gölge görüntülerinden yürüyüş tanıma ile ilgili birçok farklı çalışma literatürde vardır [18-24]. İnsanların yürüyüş görüntülerinin kamera ile kayıt altına alınması ve bunların analiz edilerek yapılan birçok farklı çalışma vardır [25-27].

Yalabık ve ark. [28] 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 [29] tarafından 11 sağlıklı deneğin 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 ve ark. [30] ise altı farklı sağlıklı genç deneğin kalçasına takılan cep telefonu yardımıyla ivmeölçer verilerini toplamıştır. Yavaş, normal ve hızlı yürüme hızındaki bu veriler temel bileşen analizi (PCA) ile hesaplanan kümülantlarda boyut indirgemesi kullanılarak özellik çıkarımı yapılmıştır. Destek vektör makineleri (SVM) ile gerçekleştirilen sınıflandırmada %90,3 başarı oranı elde edilmiştir. Benzer şekilde Sprager ve Zazula [31] tarafından da deneklerin kalçasına yerleştirilen cep telefonu yardımıyla ivmeölçer sensörü kullanılarak veriler toplanmıştır. Altı farklı deneğin normal, yavaş ve hızlı yürüme hızlarındaki verilerinden destek vektör makineleri yöntemi ile %93,1 başarılı sınıflandırma elde edilmiştir. Si ve ark. [32] 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 özellik çıkarımı yapılmış ve %93,57 başarılı sınıflandırma elde edilmiştir. Bir başka çalışmada ise kemer üzerine yerleştirilen ivmeölçer kullanılarak 36 deneğin yürüyüş verileri toplanmış ve yaklaşık %88 başarılı sonuçlar elde edilmiştir [33]. Kullanıcıların sağ alt bacağına takılan ivmeölçer tabanlı bir başka sistem [34] ile kullanıcıların ayak bileklerine takılan iki eksenli jiroskop verilerinin kullanıldığı [35] çalışmalar vardır. Bir başka çalışmada ise 59 denek üzerinde akıllı saatin içinde yer alan ivmeölçer ve jiroskop verileri kullanılmıştır [36]. İvmeölçer için en yüksek %98,3 ve jiroskop için en yüksek %94,8 başarı oranı elde edilmiştir. Zou ve ark. [37] 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 ve ark. [38] 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 [39-42]. Benzer şekilde insanların yürüyüşlerinden kaç yaşında olduğunu tahmin eden farklı çalışmalar da vardır [43-46].

3. AMAÇ VE KAPSAM

Sensörlerden yararlanarak insanları yürüyüşlerinden ayırt etme zemine sensör yerleştirme [47], ayakkabıya sensör yerleştirme [48] veya vücuda sensör yerleştirme [49] 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. Şekil 1’de bir akıllı telefonun hareket yönleri gösterilmiştir. Bu sensör yardımıyla her üç eksendeki 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 tanımının gerçekleştirilmesi diğer yöntemlere kıyasla avantajlıdır. Bu özelliği nedeniyle veri toplamak daha kolay ve ucuzdur. Bu özellik akıllı telefon ile çeşitli kimlik tanıma çalışmaları geliştirilmesine [50-52] ve yürüyüş analizi çalışmaları [53-55] 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 [56-58]. 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 tanımında önemli bir avantajı vardır.

Bu 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. ÖZELLİK ÇIKARMA

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. Özellik çıkarma algoritması olarak da bilinir ve çok verimli bir algoritmadır. Çoğunlukla görüntü işleme 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 Denklem 1'de verilmiştir.


$$LBP(x_c) = \sum_{i=0}^{P-1} s(x_i - x_c)2^i \quad s(a) = \begin{cases} 1, & \text{if } a > 0 \\ 0, & \text{otherwise} \end{cases}$$

P: Komşu piksel sayısı

n_i: i numaralı komşu piksel

c: Merkez piksel

Şekil 2'de verilen tabloda 3x3'lük bir blok için bu hesaplamaların 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 tablo elde edilir. Bu tabloda elde edilen 0 ve 1'ler sol üst köşeden başlanarak yazılır ve 2'lik tabandan 10'luk tabana dönüştürülür.

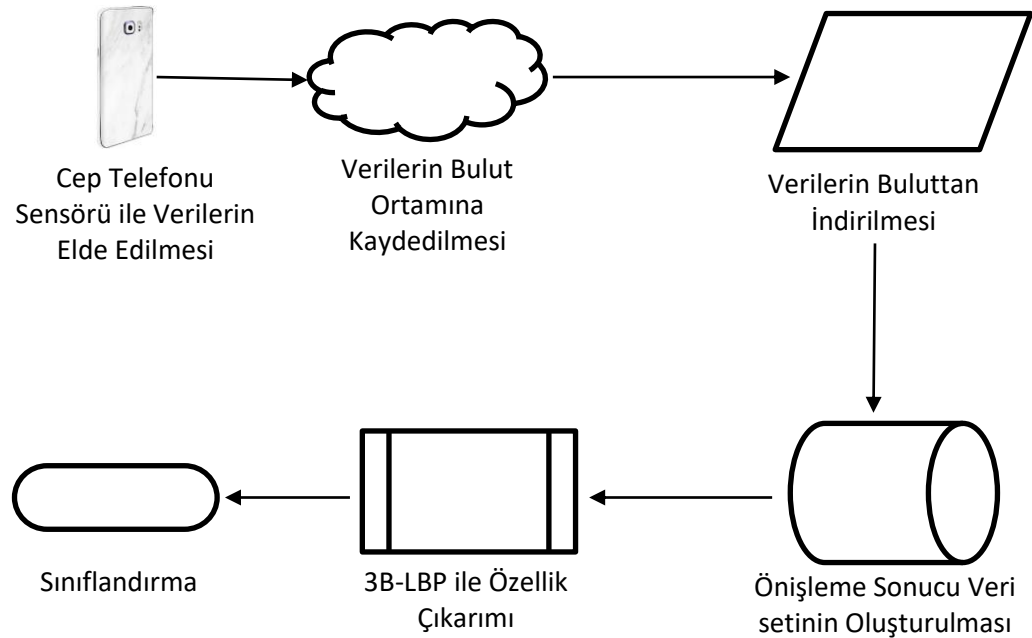


Şekil 2. Örnek LBP Kodlama

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

4.2. Üç Boyutlu Yerel İkili Desen İle Özellik Çıkarma

Bu 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 özellik 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 özellik çıkarımının detayları psuedo 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 özellik 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 2’de ise bu çalışma için, v_i değeri o gösterilirken *center* değeri d ile gösterilmektedir.

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

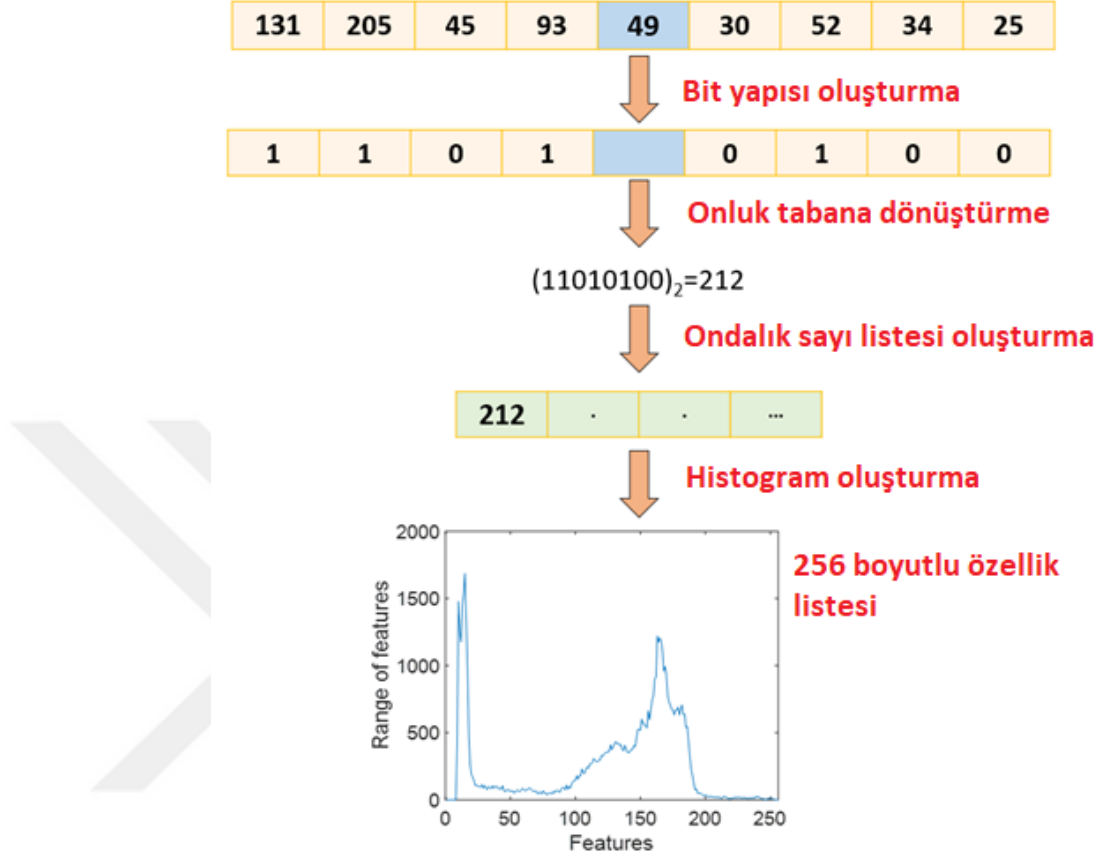
$$bit_i = sgnm(v_i, center), i = 1, 2, \dots, 8 \quad (2)$$

- **Adım 5.3:** Sadece 0 ve 1’lerden oluşan 2’lik tabandaki sayıyı 10’luk tabana dönüştür. Bunun için Denklem 3 kullanılır.

$$dcv = \sum_{t=1}^8 bit_t * 2^{8-t} \quad (3)$$

- **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 şekil 5'te gösterilmiştir.



Şekil 5. Adım 5 özeti

- **Adım 6:** Adım 5'teki işlemleri Y ve Z koordinat verilerine de uygula
- **Adım 7:** Çıkarılan özellik 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 [59]. Torbalama (bagging) [60] ve rastgele orman (random forest) [61] topluluk sınıflandırmasının iki önemli örneğidir ve karar ağaçlarına odaklanmış olup performansı iyileştirmeyi amaçlamaktadır. Bagging (bootstrap aggregation) yönteminde her alt uzay eğitim veri seti ile aynı boyuta sahiptir. Bu

nedenle içerisinde bir örnek birden fazla kez tekrar edebilir (asıl veri setinin yaklaşık %63'ü). Böylece öğrenme performansını arttıran çeşitli sınıflandırıcılar elde edilir [62]. 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 [63, 64]. 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 [65]. Alt uzay kNN, veri setindeki belirli sayıda özniteliğin alt kümelerini rasgele seçer ve sınıflandırır [66]. 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 öznitelik alt kümeleri kullandığından, göreceli olarak çok sayıda özniteliğe sahip problemler için daha iyi sonuçlar sağlayabilir [67]. Bu yöntem buradaki çalışmada çok sayıda özniteliğe sahip veri seti kullanıldığı için tercih edilmektedir.

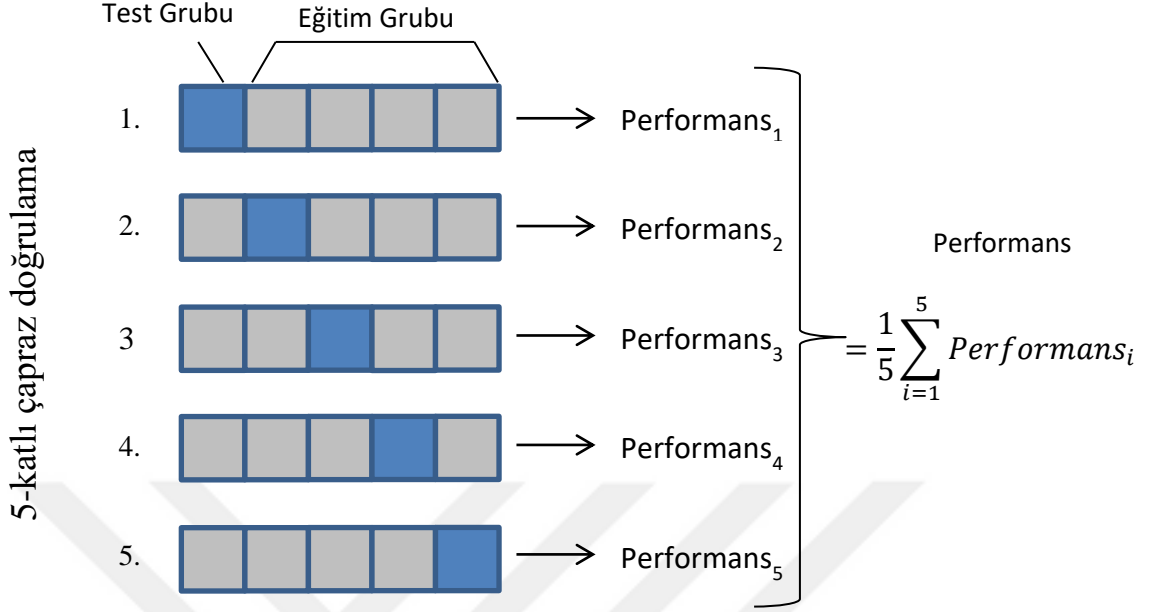
4.4. Eğitim ve Test Verilerin Ayrıştırılması

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 ayırmda 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 [68]. Bu yöntem verimlilik açısından tercih edilebilir bir yöntemdir [69, 70]. Bu yöntemin çalışma algoritması aşağıdaki gibidir.

- **Adım 1.** Veri setini rastgele karıştır
- **Adım 2.** Veri setini 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 yönteme ait algoritmanın adımları yukarıda verilmiştir. Bu algoritmanın daha iyi anlaşılması adına örnek olarak 5-katlı çapraz doğrulama algoritmasının görsel olarak anlatımı Şekil 6'da verilmiştir.



Şekil 6. Çapraz Doğrulama Algoritması

Çapraz doğrulama yöntemi kullanılarak verilerin ayrıştırılmasında çoğunlukla 10-katlı çapraz doğrulama kullanılır [71]. 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. [72]

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. 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 tabloda 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 denklemlerde bu hesaplama ait formüller verilmiştir.

$$\text{Doğruluk oranı} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Hata oranı} = \frac{FP + FN}{P + TN + FP + FN}$$

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.

$$Kesinlik = \frac{TP}{TP + FP}$$

$$Duyarlilik = \frac{TP}{TP + FN}$$

Kesinlik deęeri doęru sınıflandırılmış ve gerçekte de doęru olan deęerlerin toplam doęru diye sınıflandırılan deęerlere bölümüdür. Duyarlilik ise gerçekte doęru olan ve doęru sınıflandırılmış deęerlerin doęruyu yanlış olarak tahmin edilen deęerler ile olan toplamına bölümüdür. Fakat bu iki ölçüt tek başlarına anlamlı bir karşılaştırma sağlamakta yetersiz olmasından dolayı her iki ölçütü beraber deęerlendiren F-ölçütü deęeri vardır. Bu deęer kesinlik ve duyarlilięin harmonik ortalaması olup ařaęıdaki denklemden verilmiřtir.

$$F - ölçütü = \frac{2 \times Duyarlilik \times Kesinlik}{Duyarlilik + Kesinlik}$$

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. 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 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. Şekil 9’da kemerin fotoğrafı gösterilmiştir.




Şekil 9. Kemer ve Cep Telefonu Tutacağı

Toplam bir gidiş uzunluğu 100 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 Tablo 1’de verilmiştir.

Tablo 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. Tablo 1 içerisinde verilen minimum, maksimum ve ortalama değerler verilerin nasıl dağıldığını kısmen anlatmaktadır. Her bir kişiye ait yaş, boy ve kilo verilerin nasıl dağıldığı 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 100 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. 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. Şekil 12’de yürüme alanlarının fotoğrafları gösterilmiştir.




Şekil 12. Koridorların Fotoğraf Görüntüsü

5.2. Verilerin Analizi

Yürüme veriler 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 özellik vektörüne dönüştürülmüştür. Toplam üç eksen için 768 sütunlu bir özellik vektörü oluşturulmuştur. Matlab 2019b programı kullanılarak yapılan bu analizler sonucu veri seti ön işleme aşamaları tamamlanmış ve sınıflandırma algoritmalarına sunulacak hale dönüştürülmüştür.

Verilerin ön işleme aşamasında örnek olarak rastgele seçilen beş farklı kişinin yürüme verileri analiz edilerek bir grafiğe dönüştürülmüştür. 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 eksen de 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 öznelik 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. Tablo 2’de her bir sınıflandırma algoritmasının sonuçları gösterilmiştir.

Tablo 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	59,9
	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

Tablo 2 incelendiğinde en yüksek sınıflandırma başarısının Subspace KNN yöntemi ile 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. 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 tablo 3 içinde gösterilmiştir.

Tablo 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. Tablo 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.

Tablo 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
SVM	Linear SVM	95,0
	Quadratic SVM	96,1
	Qubic SVM	96,2
	Fine Gaussian SVM	81,2
	Medium Gaussian SVM	93,8
	Coarse Gaussian SVM	81,2
KNN	Fine KNN	90,6
	Medium KNN	89,6
	Coarse KNN	81,2
	Cosine KNN	97,8
	Cubic KNN	88,1
	Weighted KNN	89,6
Ensemble	Boosted Trees	96,2
	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.

Tablo 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. TARTIŞMA 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 ve ark. [73] 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 ve ark. [74] 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. Muazz ve Mayrhofer [75] 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 [76] ise 25 kişilik bir gruptaki uygulamasında %100 sınıflandırma başarısı elde etmiştir. Fakat bu başarı oranının test veri seti için olduğunu ifade etmiştir. Test veri seti ise rastgele seçilen %25'lik veri setinden oluşmaktadır. Buradaki çalışmadan daha yüksek bir başarı oranı elde etmesinin veri setinin özelliklerinden ya da rastgele seçilmiş olan test veri kümesinden kaynaklı olabileceği düşünülmektedir. Kwapisz ve ark. [77] 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, Deng ve Meltzner [78]'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 [79, 80] da buradaki çalışma ile benzerliği düşük olmasından

dolayı karşılaştırma yapılmamıştır. Yine benzer şekilde yürüyüş tanıma için görüntü işleme ile yapılan çalışmalar da vardır [81, 82] 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 özellik çıkarma analizi uygulandıktan sonra sınıflandırma algoritmaları yapılmıştır. İvmeölçer sensörünün X, Y ve Z koordinatına ait verilerden 768 öznitelik çıkarımı yapılmıştır. Subspace KNN algoritması ile %97,2 oranında başarılı kişi tanıma sonucu elde edilmiştir. 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.

KAYNAKLAR

1. BenAbdelkader, C., R. Cutler, and L. Davis. *Motion-based recognition of people in eigengait space*. in *Proceedings of Fifth IEEE international conference on automatic face gesture recognition*. 2002. IEEE.
2. Wang, L., et al., *Silhouette analysis-based gait recognition for human identification*. IEEE transactions on pattern analysis and machine intelligence, 2003. **25**(12): p. 1505-1518.
3. Bingham, G.P., R.C. Schmidt, and L.D. Rosenblum, *Dynamics and the orientation of kinematic forms in visual event recognition*. Journal of Experimental Psychology: Human Perception and Performance, 1995. **21**(6): p. 1473.
4. Murray, M.P., A.B. Drought, and R.C. Kory, *Walking patterns of normal men*. JBJS, 1964. **46**(2): p. 335-360.
5. Dewar, M. and G. Judge, *Temporal asymmetry as a gait quality indicator*. Medical and Biological Engineering and Computing, 1980. **18**(5): p. 689-693.
6. Balasubramanian, C.K., et al., *Relationship between step length asymmetry and walking performance in subjects with chronic hemiparesis*. Archives of physical medicine and rehabilitation, 2007. **88**(1): p. 43-49.
7. Shorter, K.A., et al., *A new approach to detecting asymmetries in gait*. Clinical Biomechanics, 2008. **23**(4): p. 459-467.
8. Cunado, D., M.S. Nixon, and J.N. Carter, *Automatic extraction and description of human gait models for recognition purposes*. Computer Vision and Image Understanding, 2003. **90**(1): p. 1-41.
9. Bouchrika, I. and M.S. Nixon, *People detection and recognition using gait for automated visual surveillance*. 2006.
10. Lee, S., Y. Liu, and R. Collins. *Shape variation-based frieze pattern for robust gait recognition*. in *2007 IEEE Conference on Computer Vision and Pattern Recognition*. 2007. IEEE.
11. Liu, Y., R. Collins, and Y. Tsin. *Gait sequence analysis using frieze patterns*. in *European Conference on Computer Vision*. 2002. Springer.
12. Lamar-León, J., E.B. García-Reyes, and R. Gonzalez-Diaz. *Human Gait Identification Using Persistent Homology*. 2012. Berlin, Heidelberg: Springer Berlin Heidelberg.
13. Tong, S., et al. *Gait identification by joint spatial-temporal feature*. in *Chinese Conference on Biometric Recognition*. 2017. Springer.
14. Arora, P., M. Hanmandlu, and S. Srivastava, *Gait based authentication using gait information image features*. Pattern Recognition Letters, 2015. **68**: p. 336-342.
15. Chao, H., et al. *Gaitset: Regarding gait as a set for cross-view gait recognition*. in *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019.
16. Goffredo, M., J.N. Carter, and M.S. Nixon. *Front-view gait recognition*. in *2008 IEEE Second International Conference on Biometrics: Theory, Applications and Systems*. 2008. IEEE.
17. Iwashita, Y., et al. *Gait identification from invisible shadows*. in *Sensing Technologies for Global Health, Military Medicine, Disaster Response, and Environmental Monitoring II; and Biometric Technology for Human Identification IX*. 2012. International Society for Optics and Photonics.
18. Iwashita, Y., R. Kurazume, and A. Stoica. *Gait identification using invisible shadows: robustness to appearance changes*. in *2014 Fifth International Conference on Emerging Security Technologies*. 2014. IEEE.

19. Shinzaki, M., et al. *Gait-based person identification method using shadow biometrics for robustness to changes in the walking direction*. in *2015 IEEE Winter Conference on Applications of Computer Vision*. 2015. IEEE.
20. Verlekar, T.T., L.D. Soares, and P.L. Correia, *Gait recognition in the wild using shadow silhouettes*. *Image and Vision Computing*, 2018. **76**: p. 1-13.
21. Iwashita, Y., A. Stoica, and R. Kurazume. *Person Identification using Shadow Analysis*. in *BMVC*. 2010.
22. Verlekar, T.T., L.D. Soares, and P.L. Correia. *Shadow type identification for gait recognition using shadows*. in *23rd Portuguese Conference on Pattern Recognition, RECPAD*. 2017. APRP.
23. Katiyar, R., V.K. Pathak, and K. Arya, *Human gait recognition system based on shadow free silhouettes using truncated singular value decomposition transformation model*. *International Journal of Artificial Intelligence and Soft Computing*, 2014. **4**(4): p. 283-301.
24. Stoica, A., *Method for using information in human shadows and their dynamics*. 2010, Google Patents.
25. Connor, P. and A. Ross, *Biometric recognition by gait: A survey of modalities and features*. *Computer Vision and Image Understanding*, 2018. **167**: p. 1-27.
26. Semwal, V.B., et al., *An optimized feature selection technique based on incremental feature analysis for bio-metric gait data classification*. *Multimedia tools and applications*, 2017. **76**(22): p. 24457-24475.
27. Zhao, G., et al. *3D gait recognition using multiple cameras*. in *7th International Conference on Automatic Face and Gesture Recognition (FGR06)*. 2006. IEEE.
28. Yalabık, N., et al., *YAHTS: Yürüyüş Analizi ile Hastalık Tanıma Sistemi*, in *Türkiye Bilimsel ve Teknolojik Araştırma Kurumu*. 2008: Ankara.
29. Gouwanda, D. and S.A. Senanayake, *Identifying gait asymmetry using gyroscopes—A cross-correlation and Normalized Symmetry Index approach*. *Journal of biomechanics*, 2011. **44**(5): p. 972-978.
30. Sprager, S. and D. Zazula, *A cumulant-based method for gait identification using accelerometer data with principal component analysis and support vector machine*. *WSEAS Transactions on Signal Processing*, 2009. **5**(11): p. 369-378.
31. Sprager, S. and D. Zazula. *Gait identification using cumulants of accelerometer data*. in *Proceedings of the 2nd WSEAS International Conference on Sensors, and Signals and Visualization, Imaging and Simulation and Materials Science*. 2009. World Scientific and Engineering Academy and Society (WSEAS).
32. Si, W., et al., *Gait identification using fractal analysis and support vector machine*. *Soft Computing*, 2019. **23**(19): p. 9287-9297.
33. Mantyjarvi, J., et al. *Identifying users of portable devices from gait pattern with accelerometers*. in *Proceedings.(ICASSP'05). IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005*. 2005. IEEE.
34. Gafurov, D., K. Helkala, and T. Söndrol, *Biometric Gait Authentication Using Accelerometer Sensor*. *JCP*, 2006. **1**(7): p. 51-59.
35. Annadhorai, A., et al. *Human identification by gait analysis*. in *Proceedings of the 2nd International Workshop on Systems and Networking Support for Health Care and Assisted Living Environments*. 2008.
36. Johnston, A.H. and G.M. Weiss. *Smartwatch-based biometric gait recognition*. in *2015 IEEE 7th International Conference on Biometrics Theory, Applications and Systems (BTAS)*. 2015. IEEE.

37. Zou, Q., et al., *Deep Learning-Based Gait Recognition Using Smartphones in the Wild*. IEEE Transactions on Information Forensics and Security, 2020. **15**: p. 3197-3212.
38. Phillips, P.J., et al. *The gait identification challenge problem: Data sets and baseline algorithm*. in *Object recognition supported by user interaction for service robots*. 2002. IEEE.
39. Li, X., et al., *Gait components and their application to gender recognition*. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 2008. **38**(2): p. 145-155.
40. Barclay, C.D., J.E. Cutting, and L.T. Kozlowski, *Temporal and spatial factors in gait perception that influence gender recognition*. Perception & psychophysics, 1978. **23**(2): p. 145-152.
41. Barra, P., et al. *Gait analysis for gender classification in forensics*. in *International Conference on Dependability in Sensor, Cloud, and Big Data Systems and Applications*. 2019. Springer.
42. El-Alfy, E.-S. and A.G. Binsaadoon, *Automated gait-based gender identification using fuzzy local binary patterns with tuned parameters*. Journal of Ambient Intelligence and Humanized Computing, 2019. **10**(7): p. 2495-2504.
43. Makihara, Y., et al. *Gait-based age estimation using a whole-generation gait database*. in *2011 International Joint Conference on Biometrics (IJCB)*. 2011. IEEE.
44. Nabila, M., A.I. Mohammed, and B.J. Yousra, *Gait-based human age classification using a silhouette model*. IET Biometrics, 2017. **7**(2): p. 116-124.
45. Li, X., et al., *Gait-based human age estimation using age group-dependent manifold learning and regression*. Multimedia Tools and Applications, 2018. **77**(21): p. 28333-28354.
46. Mansouri, N., M.A. Issa, and Y.B. Jemaa, *Gait features fusion for efficient automatic age classification*. IET Computer Vision, 2017. **12**(1): p. 69-75.
47. Addlesee, M.D., et al., *The ORL active floor [sensor system]*. IEEE Personal Communications, 1997. **4**(5): p. 35-41.
48. Huang, B., et al. *Gait modeling for human identification*. in *Proceedings 2007 IEEE International Conference on Robotics and Automation*. 2007. IEEE.
49. Gafurov, D. and E. Snekenes, *Gait recognition using wearable motion recording sensors*. EURASIP Journal on Advances in Signal Processing, 2009. **2009**: p. 1-16.
50. Shen, C., et al., *Performance analysis of multi-motion sensor behavior for active smartphone authentication*. IEEE Transactions on Information Forensics and Security, 2017. **13**(1): p. 48-62.
51. Shuwandy, M.L., et al., *Sensor-based mHealth authentication for real-time remote healthcare monitoring system: A multilayer systematic review*. Journal of medical systems, 2019. **43**(2): p. 33.
52. Li, Y., et al., *Sensor-based continuous authentication using cost-effective kernel ridge regression*. IEEE Access, 2018. **6**: p. 32554-32565.
53. Sun, B., Y. Wang, and J. Banda, *Gait characteristic analysis and identification based on the iPhone's accelerometer and gyrometer*. Sensors, 2014. **14**(9): p. 17037-17054.
54. Zou, Q., et al., *Robust gait recognition by integrating inertial and RGBD sensors*. IEEE transactions on cybernetics, 2017. **48**(4): p. 1136-1150.
55. Cola, G., M. Avvenuti, and A. Vecchio, *Real-time identification using gait pattern analysis on a standalone wearable accelerometer*. The Computer Journal, 2017. **60**(8): p. 1173-1186.

56. Khera, P. and N. Kumar, *Role of machine learning in gait analysis: a review*. Journal of Medical Engineering & Technology, 2020. **44**(8): p. 441-467.
57. Suriani, N.S., M.H. Mustafa, and F.Y. Abd Rahman, *Gait Analysis for Rehabilitation Assessment System Simulator*. Applications of Modelling and Simulation, 2020. **4**: p. 290-296.
58. Ji, N., et al., *Appropriate mother wavelets for continuous gait event detection based on time-frequency analysis for hemiplegic and healthy individuals*. Sensors, 2019. **19**(16): p. 3462.
59. Rokach, L., *Ensemble-based classifiers*. Artificial intelligence review, 2010. **33**(1-2): p. 1-39.
60. Breiman, L., *Pasting small votes for classification in large databases and on-line*. Machine learning, 1999. **36**(1-2): p. 85-103.
61. Breiman, L., *Random forests*. Machine learning, 2001. **45**(1): p. 5-32.
62. Efron, B. and R.J. Tibshirani, *An introduction to the bootstrap*. 1994: CRC press.
63. Cherkassky, V. and F.M. Mulier, *Learning from data: concepts, theory, and methods*. 2007: John Wiley & Sons.
64. Schapire, R.E., et al., *Boosting the margin: A new explanation for the effectiveness of voting methods*. The annals of statistics, 1998. **26**(5): p. 1651-1686.
65. Cover, T. and P. Hart, *Nearest Neighbor Pattern Classification*. *IEEE Transactions on Information Theory*. IT-13, 1967: p. 19-7.
66. Ho, T.K. *Nearest neighbors in random subspaces*. in *Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR)*. 1998. Springer.
67. Karasu, S. and S. Başkan. *Classification of power quality disturbances by using ensemble technique*. in *2016 24th Signal Processing and Communication Application Conference (SIU)*. 2016. IEEE.
68. Bengio, Y. and Y. Grandvalet, *No unbiased estimator of the variance of k-fold cross-validation*. Journal of machine learning research, 2004. **5**(Sep): p. 1089-1105.
69. Stone, M., *An asymptotic equivalence of choice of model by cross-validation and Akaike's criterion*. Journal of the Royal Statistical Society: Series B (Methodological), 1977. **39**(1): p. 44-47.
70. Efron, B., *The estimation of prediction error: covariance penalties and cross-validation*. Journal of the American Statistical Association, 2004. **99**(467): p. 619-632.
71. Allix, K., et al. *Large-scale machine learning-based malware detection: confronting the "10-fold cross validation" scheme with reality*. in *Proceedings of the 4th ACM conference on Data and application security and privacy*. 2014.
72. Zhang, H., et al., *Comparisons of isomiR patterns and classification performance using the rank-based MANOVA and 10-fold cross-validation*. Gene, 2015. **569**(1): p. 21-26.
73. Sun, F., et al., *Accelerometer-based speed-adaptive gait authentication method for wearable IoT devices*. IEEE Internet of Things Journal, 2018. **6**(1): p. 820-830.
74. Zeng, W., et al. *Accelerometer-based gait recognition via deterministic learning*. in *2018 Chinese Control And Decision Conference (CCDC)*. 2018. IEEE.
75. Muaaz, M. and R. Mayrhofer, *Smartphone-based gait recognition: From authentication to imitation*. IEEE Transactions on Mobile Computing, 2017. **16**(11): p. 3209-3221.
76. Frank, J., S. Mannor, and D. Precup. *Activity and gait recognition with time-delay embeddings*. in *Proceedings of the AAAI Conference on Artificial Intelligence*. 2010.

77. Kwapisz, J.R., G.M. Weiss, and S.A. Moore. *Cell phone-based biometric identification*. in *2010 Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS)*. 2010. IEEE.
78. Zhong, Y., Y. Deng, and G. Meltzner. *Pace independent mobile gait biometrics*. in *2015 IEEE 7th International Conference on Biometrics Theory, Applications and Systems (BTAS)*. 2015. IEEE.
79. Tao, W., et al., *Gait analysis using wearable sensors*. *Sensors*, 2012. **12**(2): p. 2255-2283.
80. Derawi, M.O., P. Bours, and K. Holien. *Improved cycle detection for accelerometer based gait authentication*. in *2010 Sixth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*. 2010. IEEE.
81. Aqmar, M.R., K. Shinoda, and S. Furui, *Robust gait-based person identification against walking speed variations*. *IEICE TRANSACTIONS on Information and Systems*, 2012. **95**(2): p. 668-676.
82. Del Pozo, G.B., et al., *Speed-independent gait identification for mobile devices*. *International Journal of Pattern Recognition and Artificial Intelligence*, 2012. **26**(08): p. 1260013.