T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

# YÜKSEK LİSANS TEZİ

# ÜÇ BOYUTLU YÜRÜYÜŞ ANALİZİNDE MAKİNE ÖĞRENİMİ TABANLI CİNSİYET TESPİTİ

**Adnan WAZZEH**

**DANIŞMAN**
**Prof. Dr. Ahmet SERTBAŞ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Bilgisayar Mühendisliği Programı**

**İSTANBUL-2020**

Bu çalışma, 18.01.2021 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

**Tez Jürisi**

Prof. Dr. Ahmet SERTBAŞ I(Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Oğuzhan ÖZTAŞI
Istanbul Üniversite
Mühendislik Fakültesi

Doç. Dr. Akhan AKBULUT
İstanbul Kültür Üniversitesi
Mühendislik Fakültesi

Unvan Adı SOYADI
Üniversite
Fakülte

Unvan Adı SOYADI
Üniversite
Fakülte

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

# ÖNSÖZ

Öncellikle Yüksek lisans tez danışmanım Prof.Dr. AHMET SERTBAŞ hocama tavsiye ve desteklerinden dolayı teşekkür ederim. Ayrıca tüm eğitimim boyunca her konuda yanımda olup çalışmamı bitirmem için bana cesaret veren ve yardımcı olan Arş.Gör. Ramiz Görkem BİRDAL'a, teşekkürlerimi sunarım. Araştırmamın tüm döneminde bana yardımcı oldu.

Ayrıca bu tezi ve çalışmalarımı yazarken verdikleri manevi destek için aileme de teşekkür etmek istiyorum. Onlar olmadan bu başarı mümkün olamazdı.

Aralık 2020 Adnan WAZZEH

# İÇİNDEKİLER

**Sayfa No**

**ÖNSÖZ** ..... **iv**
**İÇİNDEKİLER** ..... **v**
**ŞEKİL LİSTESİ** ..... **vii**
**TABLO LİSTESİ** ..... **ix**
**SİMGE VE KISALTMA LİSTESİ** ..... **x**
**ÖZET** ..... **xi**
**SUMMARY** ..... **xii**
**1. GİRİŞ** ..... **1**
**2. GENEL KISIMLAR** ..... **4**
2.2 BİYOMETRİ ..... 4
2.2 YÜRÜYÜŞ BİYOMETRİSİ ..... 5
2.3 YÜRÜYÜŞ ANALİZİ LİTERATÜRÜ ..... 6
2.3.1 Giriş ..... 6
2.3.2 Terminoloji ..... 7
2.3.3 Yürüyüş Tanımada Yaklaşımlar ..... 9
2.3.4 Yürüyüş Tanıma Çerçevesi ..... 10
**3. MALZEME VE YÖNTEM** ..... **12**
3.1 YÜRÜYÜŞ VERİ TABANI ..... 12
3.1.1 Geleneksel Veri Tabanları ..... 12
3.1.1.1 CMU (MoBO) Yürüyüş Veri Tabanı ..... 12
3.1.1.2 Güney Florida Üniversitesi Yürüyüş Veri Tabanı ..... 14
3.1.1.3 Southampon Üniversitesi (SOTON) Yürüyüş Verileri ..... 15
3.1.1.4 Çin Bilimleri Akademisi (CASIA) ..... 15
3.1.2 Çalışmamızdaki Veri Tabanı ..... 16
3.2 YÜRÜYÜŞ ÖZELLİK ÇIKARIMI ..... 20
3.3 YÜRÜYÜŞ HAFİFLETİLMİŞ YAPAY SİNİR AĞI ..... 20
3.3.1 Evrişimli Yapay Sinir Ağları ..... 20
3.3.2 Özellik Haritası Filtreleri- MFM (Maksimum-Özellik Haritası) ..... 21
3.3.3 Düzleştirilmiş Katman ..... 23
3.3.4 Maksimum Havuzlama (Pooling Layer) ..... 23

3.4 Doğrulama yöntemleri ..... 25
3.4.1 Çarpraz doğrulama (Cross-validation) ..... 25
3.4.2 Hold-out ..... 26
3.4.3 Birisi Dışarıda Çapraz Doğrulama (Leave-One-Out Cross-Validation) ..... 26
**4. BULGULAR ..... 27**
4.1 Cinsiyet Tanıma Sonuçları ..... 27
4.2 Literatür Sonuçları ile Karşılaştırma ..... 30
4.3 Performans Analizi ..... 31
**5.** TARTIŞMA VE SONUÇ ..... 33
KAYNAKLAR ..... 34
ÖZGEÇMİŞ ..... 38

# ŞEKİL LİSTESİ

**Sayfa No**

Şekil 1.1: Kişi tanımlama… 2

Şekil 1.2: Cinsiyet Sınıflandırma 3

Şekil 2.1: Biyometrik Sistem Türleri. 5

Şekil 2.2: Yürüyüş tanıma da yaşanabilecek zorluklar. 7

Şekil 2.3: Yürüyüş Döngüsünün Duruş ve S alınım Fazlarının Gösterimi 9

Şekil 2.4: Farklı Durumlar için Yürüyüş Tanımlama Oranlarının Meta Analizi… 9

Şekil 2.5: Yürüyüş Tanıma Algoritmalarının Adımları. 10

Şekil 2.6: Arka Plan Çıkarma Algoritması. 10

Şekil 3.1: CMU Veri Tabanı. 12

Şekil 3.2: CMU VT'ndan Aynı Kişiye ait Farklı Birim Zamanlardaki Silüetler. 13

Şekil 3.3: Aynı Tipteki Farklı Kişi Yürüyüş Silüeti 14

Şekil 3.4: USF Yürüyüş Veri Tabanından Bir Örnek. 14

Şekil 3.5: CASIA A Veri Kümesinden Bir Örnek 15

Şekil 3.6: CASIA B Veri Kümesinden Bir Örnek 16

Şekil 3.7: CASIA C Veri Kümesinden Bir Örnek 16

Şekil 3.8: Reflektörlerin Tüm Vücudu Kaplayacak Şekilde Yerleştirilme Durumu 17

Şekil 3.9: Reflektör Yürüyüş Verilerinin Program Üzerindeki Görüntüsü… 17

Şekil 3.10: El ve Ayak Bölgelerinde İsimlendirilen Reflektörlerin Gösterimi 18

Şekil 3.11: Aşırı Uyma Grafik Örneği ..... 20

Şekil 3.12: ReLu ile MFM Arasındaki Fark ..... 21

Şekil 3.13: Maxout Fonksiyonunun İşleyişi ..... 22

Şekil 3.14: Düzleştirilmiş Katman Çıktısı ..... 23

Şekil 3.15: Maksimum Havuzlama Örneği ..... 23

Şekil 3.16: CNN ağ örneği ..... 24

Şekil 3.17: Ayrıntılı Gösterilmiş CNN Ağ Örneği ..... 25

Şekil 3.18: Çarpraz doğrulama Örneği ..... 25

Şekil 3.19: Birisi Dışarıda Çapraz Doğrulama Yöntemi Örneği ..... 26

Şekil 4.1: Erkek-Kadın Yürüyüş Analizi Cinsiyet Tanımlama Oranları. ..... 27

Şekil 4.2: Algoritmamiza göre tanıma oranları yürüyüş döngü sayısıyla değişmesi..... 28

Şekil 4.3: Algoritmamizdaki parametreleri değiştirerek tanıma oranları yürüyüş döngü sayısıyla değişmesi .. 29

**Şekil tablosu öğesi bulunamadı.**

# TABLO LİSTESİ

**Sayfa No**

Tablo 4.1 Algoritmanın parametreleri adım adım belirleyerek akışı .....28

Tablo 4.2 Algoritmanın parametreleri değiştirilerek adım adım belirleyerek akışı .....29

Tablo 4.3 Sonuçlar Arasında Karşılaştırma .....30

Tablo 4.4 Light CNN Mimari Yaklaşımı .....32

# SİMGE VE KISALTMA LİSTESİ

| Kısaltmalar | Açıklama |
|---|---|
| CNN | : Convolutional Neural Network |
| FC | : Fully connected |
| PCA | : Principal Component Analysis |
| ReLU | : Rectified Linear Unit |
| SVM | : Support Vector Machine |
| GEI | : Gait Energy Image |
| MFM | : Max-Feature-Map |
| EMG | : Elektromyografi |
| NIN | : Network in Network |
| CASIA | : The gait database from Chinese Academy of Sciences |
| CMU MoBo | : Carnegie Melon University Motion of Body Database |

# ÖZET

## YÜKSEK LİSANS TEZİ

### ÜÇ BOYUTLU YÜRÜYÜŞ ANALİZİNDE MAKİNE ÖĞRENİMİ TABANLI CİNSİYET TESPİTİ

**Adnan WAZZEH**

**İstanbul Üniversitesi-Cerrahpaşa**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman : Prof. Dr. Ahmet SERTBAŞ**

Son yıllardaki biyometri alanında gerek yüz tanıma gerek yürüyüş alanlarındaki derin öğrenme başarıları geleneksel öğrenme yöntemlerine kıyasla artırmıştır. Bunun en önemli sebebi büyük veri analizlerine imkân sağlayacak yüksek işlemci gücüne sahip bilgisayar sistemleridir. Biyometri alanlarındaki yürüyüş analizi verilere büyük çapta olduklarından dolayı modellemeleri daha derin ve karmaşıktır, bu nedenle daha fazla zaman tüketimi ve işlem yüküne sahiptir. Bu amaçla iyi bir performansa sahip daha az donanımı kaynak olarak tüketen bir light-CNN modeli önerilmiştir. CNN'nin katmanlarında maksimum aktivasyon işlemi için Max-Feature-Map (MFM) kullanılmıştır. Aslında bir diğer bilinen ve sıklıkla kullanılan (ReLu) fonksiyonu genelde aktivasyon fonksiyonu olarak kullanılmaktadır, ama (Relu) fonksiyonu bir eşik değer ile nöronu bastırırken, MFM fonksiyonu rekabetçi bir ilişkiyle bastırmaktadır. MFM bunun yanı sıra genel anlamda sadece gürültülü sinyalleri ayırmakla kalmaz aynı zamanda özellik seçiminde rol oynamaktadır. Burada iyi bir performansı vermekle birlikte parametreleri ve zaman kaybını azaltan bir tane ağ sunmaktayız. Modelimiz, CMU veri seti üzerinde çalıştırılmıştır ve yürüyüş cinsiyet tanıma doğruluk oranı %92.7 ye ulaşmıştır.

Ocak 2021, 51. sayfa.

**Anahtar kelimeler:** Cinsiyet tespiti, Yürüyüş hafifletilmiş yapay sinir ağı, Yürüyüş biçimi, Max-Feature-Map aktivasyon fonksiyonu

# SUMMARY

## M.Sc. THESIS

### MACHINE LEARNING BASED GENDER DETECTION IN THREE DIMENSIONAL GAIT ANALYSIS

**Adnan WAZZEH**

**Istanbul University-Cerrahpasa**

**Institute of Graduate Studies**

**Department of Computer Engineering**

**Supervisor : Prof. Dr. Ahmet SERTBAŞ**

In recent years, deep learning achievements in study areas like facial recognition and gait analysis have exceeded the achievements of traditional machine learning methods because it works better with today's processors that have big processing capacities. Likewise, these deep learning algorithms are used in gait recognition, in order to achieve better recognition performance, in the architectures of the network which are deeper and more complex, with wasting much time and space. At this point, an advanced access network (Light CNN) has been proposed, which has excellent performance and consumes less hardware resources. We introduce the concept of maximum activation to each evolutionary layer of CNN, resulting in a Max-Feature-Map (MFM). Suppressing a neuron with a threshold (ReLU), MFM suppresses a neuron in a competitive relationship. MFM not only distinguishes noisy signals in general, but also plays a role in feature selection, where one network offers good performance while reducing the parameters and time loss. The normalized layer normalizes the output properties, thus better representing the images. We evaluate our model on the CMU dataset, and the accuracy of walking recognition reached 92.7%.

January 2020, 51. pages.

**Keywords:** Gender Recognition , Light- convolutional neural network, Gait analysis, Max-Feature-Map activation function

# 1. GİRİŞ

Elektronik ortamlarda verilerin depolanma imkânlarının artması, bilgisayarların işlem kapasitelerinin yükselmesi farklı sistemlerin daha hızlı gelişmesinin önünü açmaktadır. Kişilerin fiziksel ya da davranışsal özelliklerini inceleyen biyometri bilimi hızlı gelişen bu alanlardan biridir. Biyometrik sistemler genel olarak güvenlik, tanımlama ve tanıma konusunda geniş uygulamaları nedeniyle son yıllarda hızlı gelişme göstermiştir. Cinsiyet, yaş, sağlık durumu, engellilik hali, hamilelik gibi fizyolojik durumlar özellikle güvenlik alanında doğrudan kullanılmakta ve günümüzde aktif olarak bu konular hakkında birçok çalışma yürütülmektedir [1]. Genelde sağlık bozuklukları çalışmaları tıp vb. sağlık alanlarında incelenmiş olsa da yaş, cinsiyet tespiti gibi durumlar güvenlik sistemlerinde yoğun olarak kullanılmaktadır.

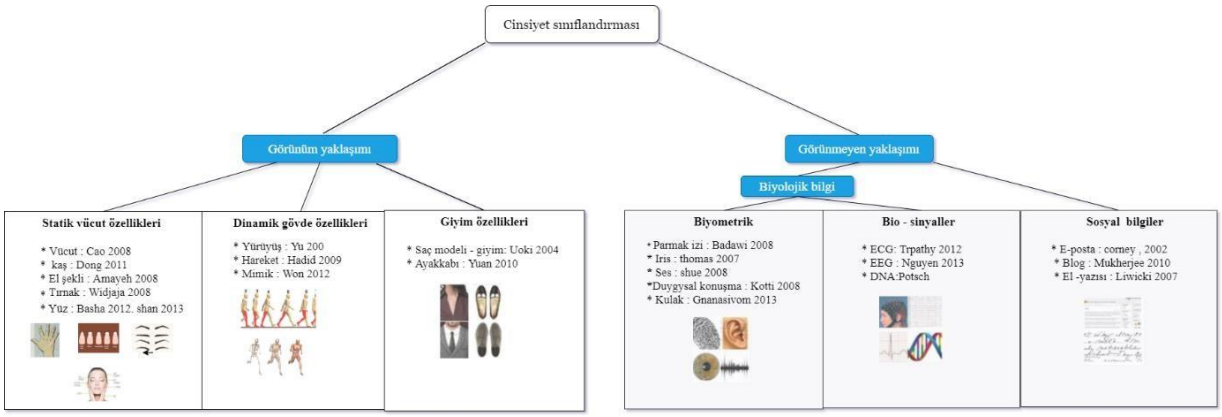
Son yıllarda birçok araştırmacı biyometrik özelliklerden en iyi şekilde faydalanmaya odaklanmışlardır. Bu sebeple popüler olan yüz ve parmak izi tanıma gibi biyometrik alanlardan farklı olarak yürüyüş biyometrisini incelemeye almışlardır. İleri teknoloji ile beraber gerek görüntü işleme alanındaki gelişim gerekse işlemci kapasiteleri bu alanda yapılan özellik çıkarımı işlemlerini pozitif olarak desteklemiştir. Bunun yanı sıra temassız veri toplama imkânına sahip olması ve diğer biyometrik verilerden farklı olarak uzak mesafelerden tespit edilmesi bu alandaki hızlı ilerlemenin belli başlı sebeplerindendir [2]. Maliyeti düşük kameralar ile veri toplama imkânının sunulması, açık ve kapalı alanlarda veri kayıtlarının alınması ve düşük çözünürlüklerde çalışma imkânının sağlanması bu pozitif kısımlardan bazılarıdır. Ayrıca yürüyüş aksiyonunun içinde yer alan karmaşık fizyolojik durumlar tanımada oldukça geniş bir özellik yelpazesi sunmaktadır. Bu yelpaze sayesinde kişilerin yaşlarının, cinsiyetlerinin vb. saptanması oldukça kolay hale gelmektedir ve başarı oranları önemli ölçüde artmaktadır. Yürüyüş alanındaki tanıma ve tespit oranlarının artması da güvenlik sistemleri gibi pek çok sistemde bu biyometrik özellikten faydalanmayı zaruri hale getirmiştir. Biyometrik verilerin toplanması, işlenmesi, arşivlenmesi ile beraber artan veri setleri öğrenme algoritmalarına da önemli destek sağlamakta ve test işlemleri de böylece daha başarılı sonuçlar üretmektedir.



**Şekil 1.1:** Kişi Tanımlama

Devlet işlerinde ve özel yaşamda pek çok biyometrik sistem, bireyler veya bir bütün olarak nüfus hakkında daha fazla bilgi edinmek için hükümetler, işletmeler ve kurumlar tarafından açık alanlarda kullanılmaktadır (Şekil 1.1). Son yıllarda, biyolojik verilerin güvenlik sistemlerinde kullanımı, benzersiz ve kişiye özel olması nedeniyle hızla artmaktadır. Bu büyümeyle birlikte, popüler çalışma alanlarında da bazı değişiklikler meydana gelmiştir.

Parmak izi, iris ve yüz tanıma gibi bazı biyometrik çalışma alanları hala popüler olmakla birlikte, 3 boyutlu yüz tanıma veya yürüyüş tanıma gibi bazı yeni çalışma alanları popüler olmaya başlamıştır. Bir başka ifadeyle özel bir yol veya tarza ait olan yürüyüşler, tespit edilmeyi bekleyen pek çok özelliği içerisinde barındırmaktadır. İnsan vücudunun bölümlerindeki hareketliliğin eşitsizliği ve farklı oranlarda değişimi bu özelliklerin ana karakteristiğini ortaya koymaktadır. Bu nedenle, bu oranları ve korelasyonları araştırmak bireysel yürüyüş stillerini ayırt etmeye yardımcı olur.




**Şekil 1.2:** Cinsiyet Sınıflandırması

Cinsiyet sınıflandırmasında görünüş ve görünüşe ait olmayan biyometrik bilgiler sayesinde sınıflandırma gerçekleştirilmektedir (Şekil 1.2) [3]. Görünüşe ait olan biyometrik bilgiler arasında ise geleneksel özellikler arasında yer alan parmak izi ve yüz yanıma statik vücut özellikleri arasında yer almakta iken yürüyüş ve duruş ise dinamik vücut özellikleri arasında yer almaktadır. Bir de bunların haricinde aksesuarların ve saçların analizi de görünüşe ait özellikler arasında yer almaktadır ve bazı durumlarda bunlar yürüyüşü etkileyen etmenler arasında bulunmaktadır. Bizim çalışmamızda ise bu durumlarından görünüşe ait olan dinamik bir biyometrik özellik olan yürüyüş kısmı incelenmiş olup bu alanda sağlıklı özellik çıkarımlarının gerçekleştirilmesi ve bu özelliklere dayanarak öğrenme gerçekleştirilmesinin akabinde başarılı cinsiyet ayırt etme işlemlerinin gerçekleştirilmesi amaçlanmıştır. Bu sayede son zamanların önemli konularından olan yürüyüş analizinde yer alan karmaşık hareket yapılarının başarılı sınıflandırmasının gerçekleştirilmesi ve böylece cinsiyet tespitinin gerçekleşmesi planlanmıştır.

# 2. GENEL KISIMLAR

## 2.1. BİYOMETRİ

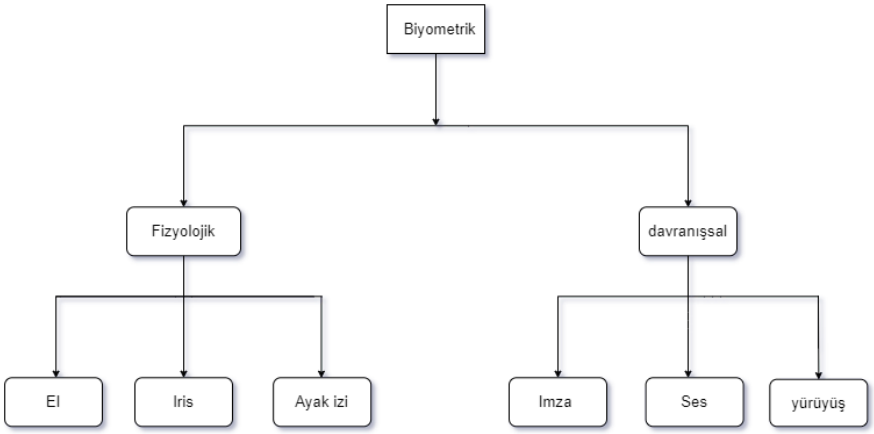
Biyometri kişinin ölçülebilir biyolojik izlerinin alınması, incelenmesi, saklanması, sınıflandırması gibi işlemleri içinde barındıran geniş bir bilim alanıdır. Diğer bir tanımla, biyometri, insanların fizikî ve davranışsal özelliklerini inceleyerek birbirinden ayırt edilebilmesini sağlayan bilim dalıdır.

Biyometri, genel kullanımında bilgisayar bilimlerinde bir tanımlama ve erişim kontrolü olarak kullanılır. Ayrıca, gözetleme altındaki gruplardaki bireyleri tanımlamak için kullanılır. Biyometrik tanımlayıcılar, kişileri etiketlemek için ve tanımlamak için kullanılan ayırt edici, ölçülebilir özelliklerdir. Biyometrik tanımlayıcılar sıklıkla fizyolojik ve davranışsal özellikler olarak sınıflandırılır.

Biyometrik sistemler temel olarak fiziksel(pasif) ve davranışsal(aktif) sistemler olmak üzere 2 gruba ayrılır [4]. Fiziksel biyometrik sistemler ses, parmak izi, yüz, ses, iris, retina olarak tanımlanabilir. Davranışsal biyometrik sistemler, yazma ritmi, yürüyüş şekli, imza dâhil ancak bunlarla sınırlı olmamak üzere bir kişinin davranışlarıyla ilgilidir. Geleneksel erişim kontrolü araçları arasında sürücü ehliyeti veya pasaportu gibi belirteç tabanlı kimlik sistemleri ve şifre veya kişisel kimlik numarası gibi bilgi tabanlı kimlik sistemleri yer almaktadır. Biyometrik tanımlayıcılar bireylere özgü olduğundan kimlik doğrulamada belirteçtir ve bilgi tabanlı yöntemlerden daha güvenilirdirler. Bunun yanında bilgisayar bilimleri konusundaki en popüler biyometrik araştırmalar yüz, parmak izi, avuç içi izi, yürüyüş veya bu özelliklerin bir kombinasyonun analiz etmektir.

Bu araştırmadaki konu ise cinsiyet sınıflandırma için biyometrik uygulama kullanılmasıdır. Çünkü cinsiyet sınıflandırma için tüm biyometreler kullanılamaz, yürüyüş, ses ve yüz bir kaç araştırmada cinsiyet sınıflandırma konusunda güzel sonuçlar vermiştir[5-7]. Bu bilgi sadece mevcut biyometrik sistemleri geliştirmekle kalmayacaktır. Aynı zamanda “akıllı alanda” örneğin, cinsiyete dayalı belirli alanlara erişimi kısıtlamada ve kontrol hizmetlerinde mesela mağazalara, havalimanlarına veya başka yerlere giren kadın sayısı nedir? Ya da artış gösteriyor mu? gibi sorulara cevap olacaktır.

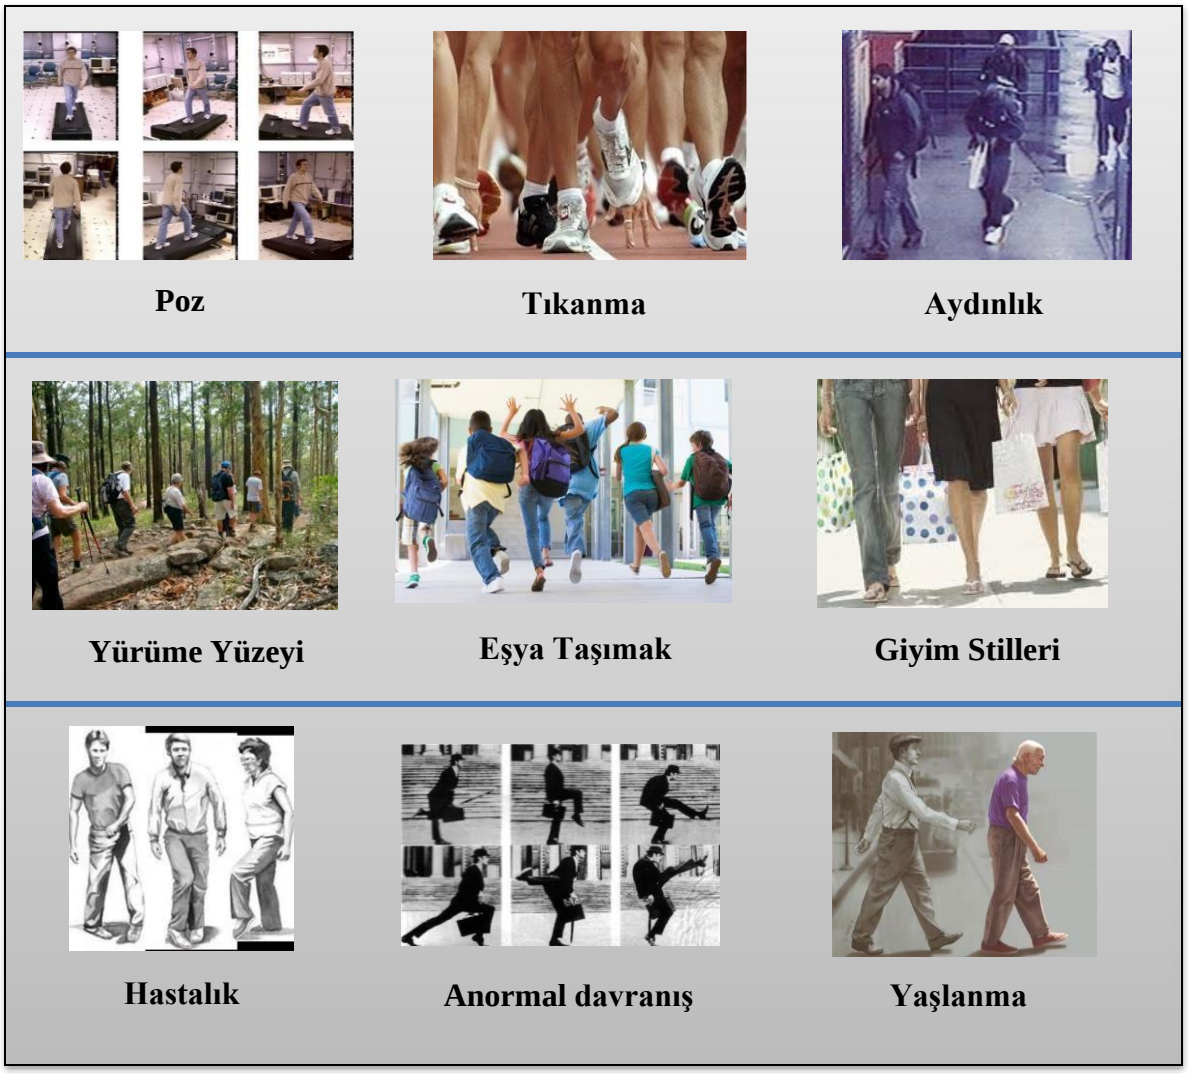
## 2.2 YÜRÜYÜŞ BİYOMETRİSİ




**Şekil 2.1:** Biyometrik Sistem Türleri

Yürüyüş yukarıda görüldüğü gibi davranışsal (behavioral) başlığının altında yer almaktadır (Şekil 2.1). Diğer biyometrik yöntemlerle karşılaştıracaksak eğer yürüyüş analizinin benzersiz özellikleri bulunmaktadır. En önemli özelliklerden birisi fiziksel bilgiye ihtiyaca duyulmadan uzak bir mesafeden kayıt altına alınabilmesidir. Başka biyometrik özellikler ise yüz, iris, imza, ses gibi fizik temasla ya da yakın mesafede yakalanmaktadır. Ayrıca yürüyüş analizinde de aldatma olayı oldukça zordur ve kişinin çok dikkat edici (göze batan) bir şey yapmasına gerek yoktur. Bir kişinin yürüyüşünü tanımlayan kinetik parametreler olmasına rağmen yürüyüşü etkileyen faktörleri belirlemesinde zorluklar vardır ve gözden kaçırılan detaylar bulunmaktadır. Bu yüzden dış çevre kontrolü olan ya da olmayan yerler de yürüyüş denemeleri çekilmiş ve videolara istinaden analiz edilmiştir.

Yürüyüşün zamanla değişebileceği ve bir kaç faktöre bağlı olduğu söylenmiştir. Mesela kişinin verdiği pozlar, ayakkabı türü ve iyi bağlanıp bağlanmadığını, Aydınlık durumu, yürüme yüzeyi, eşya taşıma durumu, kişinin giydiği elbise, Hastalık, Anormal davranış, yaşlanma, yürüyüş hızı ve duygusal durumlar ekstra olarak kişinin yürüyüşü üzerinde ekstra bir özellik daha taşır. Ayrıca biyometrik özelliklerden farklı olarak düşük çözünürlüklü olan videolardan bilgi alınabilmektedir [8].




**Şekil 2.2:** Yürüyüş tanıma da yaşanabilecek zorluklar

## 2.3. YÜRÜYÜŞ ANALİZİ LİTERATÜRÜ

### 2.3.1 Giriş

Her insanın yürüyüşünün benzersiz olduğu fikrine hatırı sayılır bir destek bulunmaktadır. On İkinci Gece'de Maria Malviolo'yu gözlemlediği bahsedilen Shakespeare: "Sakalının rengi, bacağının şekli, yürüyüş şekli ile kendini en çok bulunacak hoş bir şekilde kişileştirdi" demiştir. Biyo-mekanik literatür benzer gözlemler yapar, yürüme şeklini oldukça tekrarlanabilir bir şekilde gerçekleştirildiğini, yeterince uzak bir kişiyi yürüyüşüyle tanımanın mümkün olacağını belirtmiştir [9].

Tablo evrensellik, ayırt edilebilirlik, kabul edilebilirlik gibi çeşitli kriterlere dayanan diğer yaygın biyometrilere kıyasla yazarlarının "biyometrik olarak yürüyüş" düşüncesindeki algısını

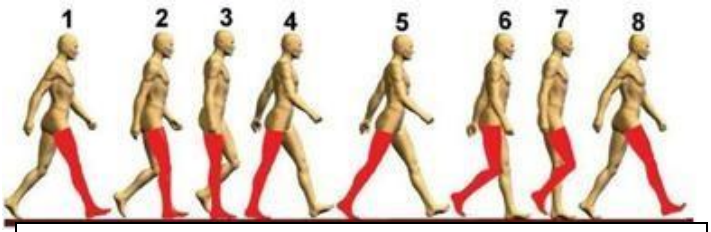
göstermektedir. Bununla birlikte, bu büyük bir veri topluluğuyla değerlendirilmemiştir ve bu nedenle farklılığı orta olarak derecelendirilmiştir. Ayrıca yürüyüş, süje ile etkileşime girmeden bile kolayca toplanabilir ve kabul edilebilirlik endeksi yüksektir.

Evrensellik endeksi ortadadır, çünkü bir kişi tamamen tıkalı giysiler giydiğinde veya devre dışı bırakıldığında toplanamaz. Yürüyüş yaşla birlikte değiştiği için kalıcılık özelliği düşük olarak derecelendirilmiştir.

Mevcut tanıma araştırması, laboratuvar koşullarında daha iyi performans ve gerçek dünya koşullarında bunu başarmaya daha fazla odaklanmaktadır.

### 2.3.2 Terminoloji

Yürüme bir yerden bir yere gidebilmek amacıyla gövdenin ilerletilmesidir. Yürüyüş ölçümü kinetik(kuvvet) ve kinematik(zamansal) bilgiler kullanılarak yapılabilmektedir. Standart bir yürüyüş değerlendirmesi en az bir tam yürüme döngüsünde, gözlemlenen bacağın bulunduğu bir ayak vuruşu diğer bacağın karşıt bir ayak vuruşu ardından gözlemlenen bacağın diğer bir vuruşu ile gerçekleştirilir.




| Basma Fazı | Salınım Fazı |
|---|---|
| 1- İlk değme (initial contact) | 6- Erken salınım (initial swing) |
| 2- Yüklenme (loading response) | 7- Salınım ortası (mid-swing) |
| 3- Basma ortası (midstance) | 8- Salınım sonu (terminal swing) |
| 4- Basma sonu (terminal stance) | |
| 5- Salınım öncesi (preswing) | |

**Şekil 2.3:** Bir yürüyüş döngüsünün duruş ve salınım fazlarının gösterimi

Yürüme döngüsü ayrıca, duruş aşamasında beş ve dönüş aşamasında üç olmak üzere altı döneme ve sekiz işlevsel olaya bölünebilir (Şekil 2.3). Birincisi, birinci çift destek dönemiyle

başlayan tek desteğiyle ardına gelen ve çift destek ile biten döneminden oluşur. İkili destek periyodu, her iki ayağın zemine eşzamanlı olarak temas ettiğinde denk gelir ve sol ve sağ tek bacaklarda destek arasındaki pürüzsüz geçişi açıklar. İlk çift destek sırasında topuk, yürüyüş döngüsünün başlangıcına işaret ederek zemine vurur (topuk vuruşu). Döngü daha sonra tek dönemli desteğe doğru gelişir, ayak zemine doğru aşağıya doğru hareket ederken, vücudun geri kalanı için sabit bir destek tabanı oluşturulur. Tek destek fazında, gövde, orta duruş olarak nitelendirilen olayda, kalça eklemi ayak bileği eklemi ile dikey olarak hizalanacak şekilde ayak üzerine itilir. Bu noktadan itibaren, ikinci çift destek aşaması, alt kolun, topuğun zemine temas etmeyi kaybettiği topuk yükselme olayı sırasında kütle merkezini ileri hareket ettirerek başlar. Ayağın zemine son teması, duruş fazının sonunu ve dönme fazının başlangıcını gösteren ayak parmağı (halluks) ile yapılır.

Yeni salınım fazın başlangıcında plantar ayak ile zemin arasında temas yoktur ve kol, üç farklı döneme ayrılabilen ileri hareketine devam eder: Başlangıç dönüşü, orta dönüş ve terminal dönüşü, dönme evresi, kalça seviyesinde daha zorlu kas eforu gerektiren alt uzuvdaki ivmeler ve yavaşlamalar ile karakterizedir.

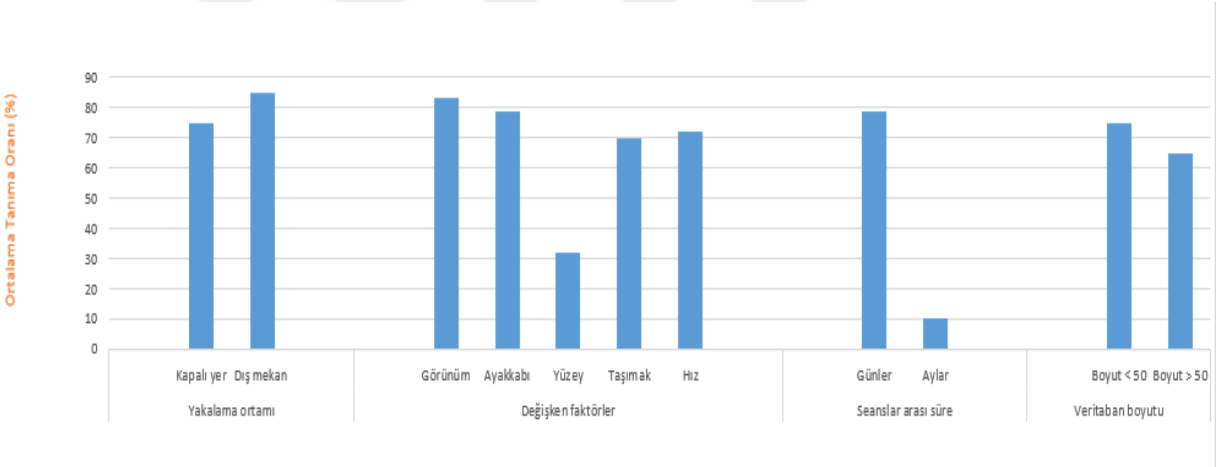
Yürüme analizi, normal yürüyüş düzenindeki negatif sapmaların ve bunların nedenlerinin algılanmasını sağlayan sistematik bir işlemdir. Bu analizlere dayanarak, alt uzuvların hareketinde yer alan parametreleri ölçmek ve insan vücudunun hareketini yöneten mekanizmaları almak mümkündür, Daha önce tarif edilen yürüyüş döngüsü düzenine dayanarak, hastanın sağlığını değerlendirmek için fiziksel olarak izlenebilecek birkaç parametre vardır: Antropometrik, mekansal-zamansal, kinematik, kinetik ve dinamik elektromiyografi (EMG).

Bu yüzden yürüyüş analizi önemlidir. Bir kişinin nasıl yürüdüğünü veya kaçtığını incelediğimizde, bireylerin benzersiz hareketlerini tanımlayabilir, normal yürüyüş düzenlerini belirleyebilir, ağrıya neden olan sorunları teşhis edebilir ve ayrıca anormallikleri düzeltmek için tedaviler uygulayabilir ve değerlendirebiliriz.[10]

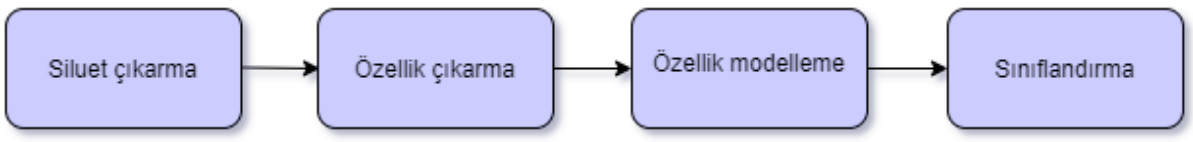
### 2.3.3 Yürüyüş Tanımada Yaklaşımlar

Yürüme tanımada mevcut yaklaşımlar genel olarak görünüşe ve modele dayalı olarak kategorize edilmektedir. Görünüşe dayalı yaklaşımlar, siluetin hareket şeklini veya hareket eden şekil ve hareketten gelen bilgilerin entegrasyonunu temel alır. İçinde görünüşe dayalı yaklaşımlar, yürüyüş bilgisi yapısal model veya hareket modeli ile elde edilir.

Aşağıdaki tabloda, CMU MoBo, SOTON ve CASIA gibi en yaygın veri tabanlarındaki en son teknoloji algoritmalar için yürüyüş tanımanın meta analizini (etkileyen faktörlerin farklı bilgilerinin birleşimi) ortalama sonuçları göstermektedir. Bu olabilir bir iç ortamın% 80'lik bir tanımlama oranına ulaştığı, ancak dış ortamlarda tanımlama oranının% 10'un üzerinde olduğu görülmektedir. En önemli düşüşler yüzeydeki değişiklikler ve büyük test seans Aralıkları (6 ay) nedeniyle oluşur.




**Şekil 2.4:** Farklı durumlar için yürüyüş tanımlama oranlarının meta analizi




**Şekil 2.5:**Yürüyüş tanıma algoritmanın adımları

Yürüyüş tanıma algoritmalarının temel bileşenleri yukarıda görüldüğü gibidir (Şekil 2.5). İlk başta, siluetler çıkarılır ve arka plan çıkarma algoritmaları kullanılarak önceden işlenir. Daha

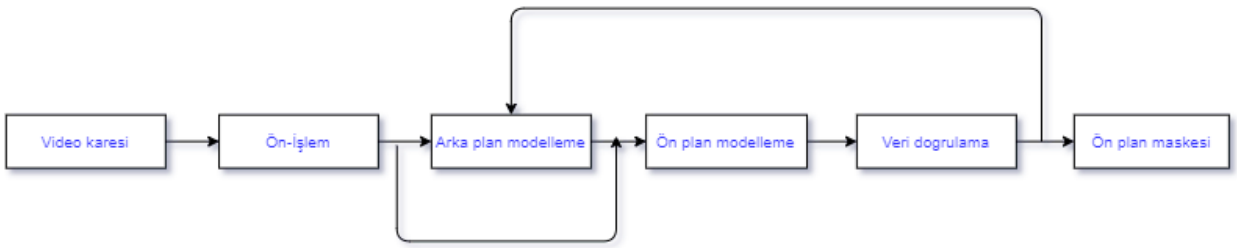
sonra, yürüyüş özellikleri bölümlenmiş siluetlerden hesaplanır ve bu yürüyüş özellikleri daha iyi ayırt edilebilir öğeleri kodlamak için modellenir. Son olarak, testin bu modellenmiş özellikleri özne, kimliği talep etmek için önceden kaydedilmiş veri tabanında karşılaştırılır.

### 2.3.4 Yürüyüş Tanıma Çerçevesi

Yürüyüş tanıma için tipik bir çerçeveyi açıklamaktadır. Başlangıçta, video dizilerinden insan siluetlerini çıkarmak için segmentasyon işlemleri uygulanır. Siluetlerin normalleştirilmesi de dâhil olmak üzere bir dizi işlem sonrası görev, çıkarılan siluetlere ortak bir platformda kaydetmek için uygulanır. Daha sonra, yürüyüş özellikleri, kişiye özel yürüyüş bilgisini kodlamak için çıkarılır ve modellenir. Son olarak, benzerlik mesafesini hesaplamak için sınıflandırma yapılır. Bu da kişinin kimliğini talep etmek için kullanılacaktır. Çerçevedeki tüm bu süreçler içinde en önemli adım, özneleri benzersiz bir şekilde ayırt edebilen uygun yürüyüş özelliğini çıkarmaktır. Mevcut özellik çıkarma yöntemleri genellikle şöyle sınıflandırılabilir; görünüşe dayalı yöntemler ve modele dayalı yöntemler. Hem görünüme dayalı hem de model tabanlı yöntemler 2B veya 3B veri kaynakları. Bu bölümde, yürüyüş tanıma çerçevesindeki ana bileşenlerle ilgili araştırmalar ele alınmaktadır: siluet segmentasyonu, özellik çıkarma, özellik modelleme ve sınıflandırma.

Birçok bilgisayar görme uygulamasında olduğu gibi, insan silueti tanımlamak yürüyüş tanımada temel bir görevdir [12]. Yaygın bir yaklaşım, insan siluetini sahnede hareketli bir nesne olarak tanımlayan arka plan çıkarması yapmaktır.

Bu, önemli boyutta birkaç nesnenin hareket ettiği çok etkilidir. Arabalar gibi ek konuların sahnedeki insanlarla birlikte hareket ettiği durumlarda algılama zorlaşır. Bu durumda, insanları diğer hareketli nesnelerden ayırmak için hareket maskesine basit bir boyut eşiği uygulanabilir.




**Şekil 2.6:** Arka plan çıkarma algoritması

Arka plan çıkarma algoritmalarının akış diyagramı yukarıda görüldüğü gibidir. Siluetler ilk kayıt için önceden işlenir ve arka plan modellenir. Ön alanlar eğitimli model kullanılarak tahmin edilir. Bu süreç, eğitim verileri üzerinde tekrarlanır, sağlam bir ön plan maskesi oluşturmak için arka plan modeline ince ayar yapılır. İyi bir arka plan çıkarma algoritması geliştirilir. Aydınlatmadaki değişikliklere karşı sağlam olunmalı ve sabit olmayan arka plan nesnelerini tespit etmekten kaçınılmalıdır. Bulutlar, araçlar, hareketli yapraklar ve gölgeler bunlardan bir kaçıdır [13, 14]. Videodaki bu hareketleri analiz etmenin tipik yaklaşımı optik akış kullanılmaktır [15-20]. Tipik bir arka plan çıkarma algoritması, Şekil 2.6'daki akış diyagramında gösterilmiştir. Bu, ön işleme, arka plan modelleme, ön plan algılama ve veri doğrulama olarak bilinen dört ana adımdan oluşur. Geçmişte bir dizi arka plan çıkarma tekniği geliştirilmiştir. Bu bölümde ise birkaç popüler teknik özetlenmiştir.

# 3. MALZEME VE YÖNTEM

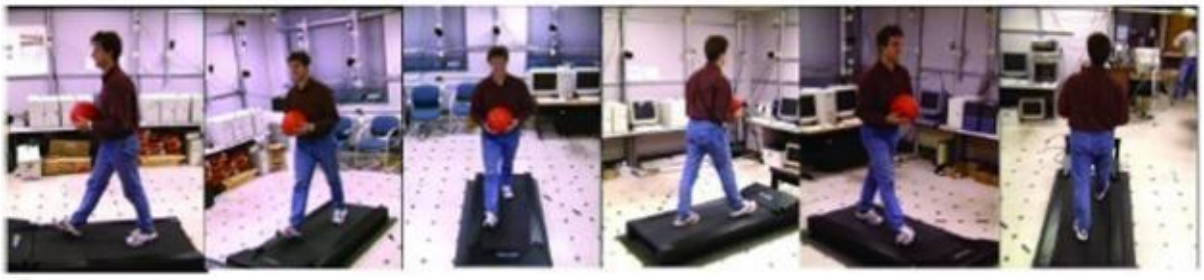
## 3.1 YÜRÜYÜŞ VERİ TABANI

Tüm yürüyüş araştırmacıları yaptıkları deneylerde genelde benzer yürüyüş veri setlerini kullanmaktadır. Yürüyüş tanıma algoritmalarını adil bir şekilde karşılaştırmak ve değerlendirmek için ise aynı veri setlerine ihtiyaç duyulmaktadır. Ayrıca başka faktörlerde bulunmaktadır. Işıklandırma ve sağlıklı bir şekilde çekim yapılması için büyük ve sade arka planlı alanlar olmalı ve gerekli donanımın kurulması gerekmektedir. Birçok veri kümesi sayabiliriz ama aralarında en meşhur olanları kısaca belirtmek gerekir ise [21-26]; CMU(MoBO) yürüyüş veri tabanı, ABD deki güney Florida üniversitesinde yapılan (USF) veri seti, ve İngiltere'den Southampton üniversitesinden (Soton) veri seti ve Çin bilimler akademisinden (CASIA) gait seti. Bu araştırmada ise bunların haricinde "The Carnegie Mellon University Gait Database" kullanılmıştır.

### 3.1.1. Geleneksel Veri Tabanları

#### *3.1.1.1 CMU (MoBO) Yürüyüş Veri Tabanı*

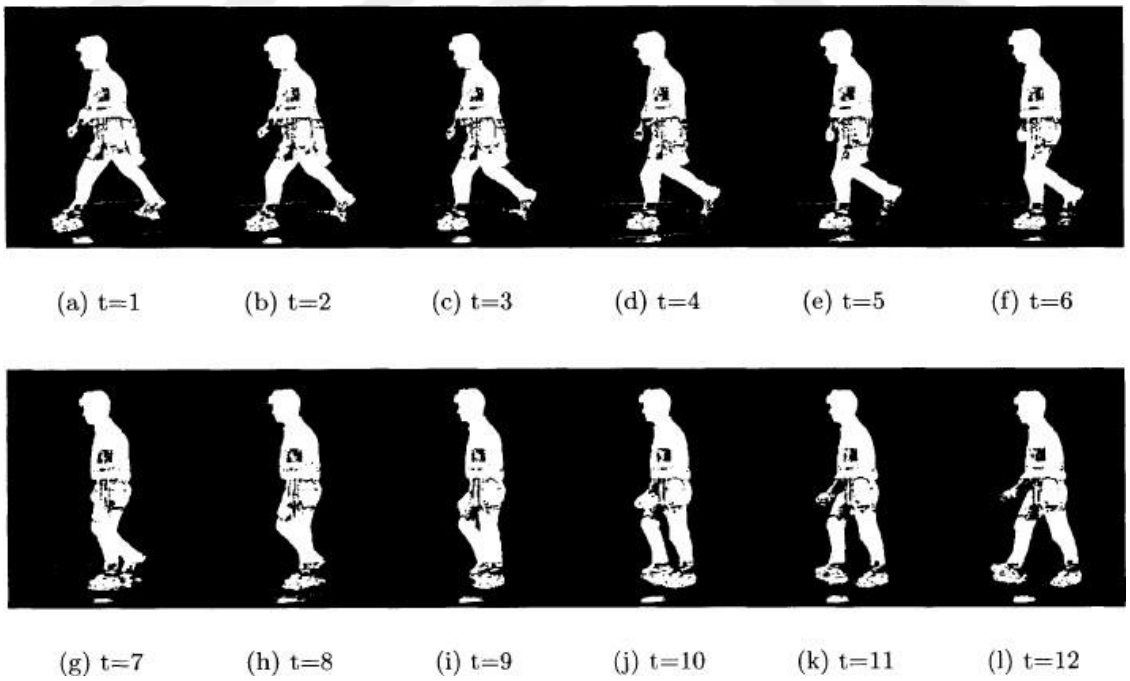
Mart 2001'de CMU Vücut Hareketi (MoBo) veri tabanını toplanmaya başlanmıştır. Veri tabanına, CMU 3D odasında koşu bandında yürüyen 25 kişiden alınmıştır. Kişiler dört farklı yürüyüş düzeni gerçekleştirmektedir: yavaş yürüyüş, hızlı yürüyüş, eğimli yürüyüş ve topla yürüyüş. Tüm kişiler, koşu bandının etrafında eşit bir şekilde dağılmış altı yüksek çözünürlüklü renkli kamera kullanılarak yakalanır. Bu teknikte, yakalama kurulumunu, toplama prosedürünü ve veri tabanının organizasyonu açıklanmıştır.



**Şekil 3.1:** CMU Veri tabanı

CMU veri kümesi (Şekil 3.1 ), bir koşu bandı üzerine yürüteç kişilerin çoklu görünümü, vardır. Her kişi 3 faklı yürüyüş şekli göstermektedir: birincisi top tutarak yürüyüş, sonra hızlı yürüyüş ve yavaş yürüyüş. Her yürüme dizisi, bir kaç açıdan çekilmiş 30 kare her saniyede kaydedilecek şekilde 10 saniyeden ve daha fazladır. CMU tarafından sağlanan ön plan siluetleri kullanılmıştır ve bu siluetleri arka planda tek bir görüntüden basit bir arka plan çıkarılması ile üretilmiştir. Aşağıdaki resim bir kaç siluet örneği göstermektedir (Şekil 3.2). Bu veri kümesinden, alt dizilerin arasında karşılaştırma işlemi yapılsın diye her dizi 60 alt diziye bölünmektedir, toplam 25 kişi,23 erkek ve 2 kız ve 3 tane yürüyüş şekli ve her bir şekil için 5 tane altdizinin oluşuyor buda sonuç olarak 370 tane alt dizi üretmektedir.

CMU veri seti, yürüyen kişinin aynı yere sabitlendiğini ve aynı sabit çevre aydınlatma koşulların altında, siluetlerdeki gürültünün her dizide sabittir ve tanıma amaçlı kullandığımız alt dizilerin arasında aynı şekilde, sağdaki şekilde yürütecin altındaki bölgeyi gösterir ve çerçevenin çoğu koşu bandının kenarlarını gösterir. Şekilde gösterilen örnekte aynı tipte siluet gürültüsüne sahip üç farklı kişiden alınan örnek siluetler gösterilmektedir (Şekil 3.3). Aynı tür yürüyüş yapmaktadırlar.




**Şekil 3.2:** CMU veri tabanından aynı kişiye ait farklı birim zamanlarında siluet görüntüleri



(a) (b) (c)

**Şekil 3.3:** Farklı kişi ayni tipteki yürüyüş için siluet

### *3.1.1.2. Güney Florida Üniversitesi Yürüyüş Veri Tabanı*

Bu veri tabanının içinde ham görüntü dizileri bulunmaktadır. Veriler,20-21 Mayıs 2001 ve 15-16 Kasım 2001 tarihlerinde dört gün boyunca Güney Florida Üniversitesi'nde (Şekil 3.4 ). ABD de toplanmıştır. Veri kümesi kameralar önünde eliptik yollarda yürüyüş yapan insanlardan oluşmaktadır. Her bir kişi 5 defadan fazla elipsin etrafında yürümüştür, kullanılan ekipmanı ise belirtilmemiştir.

Burada 5 tane değişken yer almaktadır:

- 2 farklı ayakkabı tipi giyilmiş

- 2 farklı taşıma koşulu

- 2 Farklı yüzey tipinde

- 2 farklı açılardan bakılmaktadır

- 2 farklı zaman aralarında ve her bir kişinin önünde 32 olasılığı vardır.



**Şekil 3.4:** USF yürüyüş veri tabanından bir örnek

### *3.1.1.3. Southampon Üniversitesi (SOTON) Yürüyüş Verileri*

İki tane veri tabanından oluşmaktadır. Büyük popülasyonu olan fakat içinde çok ayrıntı içermeyen ile küçük olan ve ayrıntı içeren iki veri tabanı bulunmaktadır. Büyük olan veri tabanında, normal kişinin yürüyüşü normal şartlarda yapılmıştır. Küçük veri tabanı ise biyometrik teknikleri aynı kişiler için ortak koşullarda (eşya taşıması, farklı kıyafetler veya ayakkabılar giyme) içinde yapılmıştır.

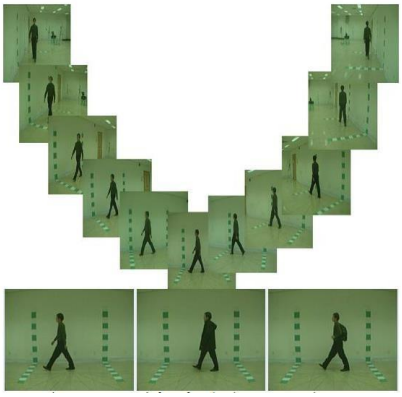
### *3.1.1.4. Çin Bilimleri Akademisi (CASIA)*

CASIA veri tabanında 3 tane veri seti vardır: A veri kümesi, B veri kümesi, ,C veri kümesidir. A veri kümesi (Şekil 3.5). 10 Aralık 2001 de 20 kişiden oluşmaktadır her biri 12 görüntü dizisine sahiptir, her 4 dizi görüntü düzlemine 45 ve 90 dereceye sahiptir A'nın büyüklüğü yaklaşık 2,2 GB ve veri tabanı 19139 görüntü içermektedir



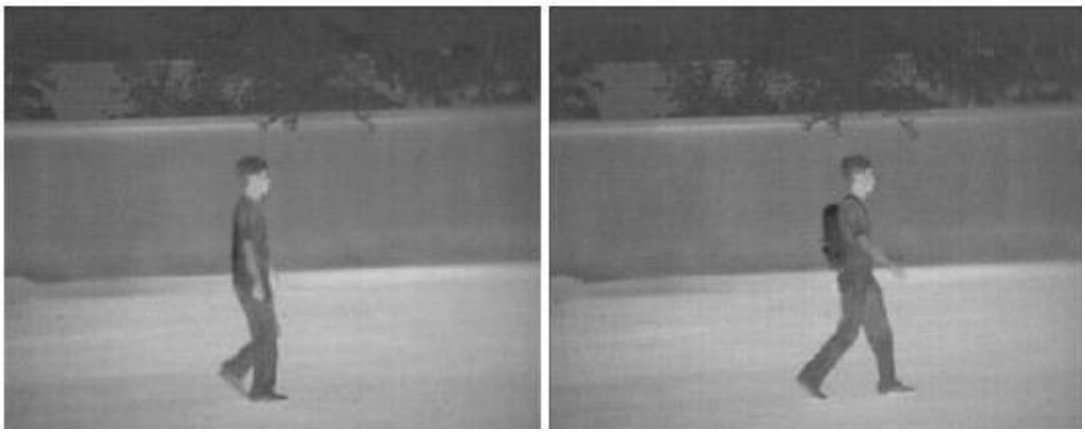
**Şekil 3.5:** CASIA A veri kümesinden yürüyüş veri tabanından bir örnek

B Veri Kümesi (Şekil 3.6). Ocak 2005'te oluşturulan büyük birçok görüntü içeren yürüyüş veri tabanıdır. 124 kişi vardır ve yürüyüş verileri 11 görünümden elde edildi. Görüş açısı, giysi ve taşıma durumu değişiklikleri olmak üzere üç farklılaşma ayrı ayrı göz önünde bulundurulur. Video dosyalarının yanı sıra, hala video dosyalarından çıkan insan siluetleri sağlar.



**Şekil 3.6:** CASIA B veri kümesinden yürüyüş veri tabanından bir örnek

C Veri kümesi (Resim 3.7), 2005 Temmuz-Ağustos aylarında bir termal kamera tarafından toplanmıştır. 153 kişi içeriyor ve dört yürüyüş koşulunu dikkate almaktadır: normal yürüyüş, yavaş yürüyüş, hızlı yürüyüş ve bir çantayla normal yürüyüş. Videoların hepsi gece ortamında çekilmiştir.



**Şekil 3.7:** CASIA C veri kümesinden yürüyüş veri tabanından bir örnek

### 3.1.2. Çalışmamızdaki Veri Tabanı

Carniege Mellon Üniversitesi'nin hareket yakalama laboratuvarından elde edilen 3 boyutlu yürüyüş verileri, tezin çalışma verisi olarak kullanılmıştır. Tez çalışması kapsamında kişilerin üzerinde yer alan reflektörler sayesinde elde edilmiş yürüyüş konum verileri kullanılmıştır. Reflektörler tüm vücudu kapsayacak şekildeki gibi yerleştirilmiştir. (Şekil 3.8)



**Şekil 3.8:** Reflektörlerin tüm vücudu kaplayacak şekilde yerleştirilme durumu

Cmotion programında elde edilen verilerin görüntüsü şekildeki gibi oluşmaktadır (Şekil 3.9). Tüm reflektörler 3 boyutlu uzayda kişilerin uzuvları ve gövdelerinin nasıl hareket ettiğini matrislerde depolama imkânını bize sunmaktadır.



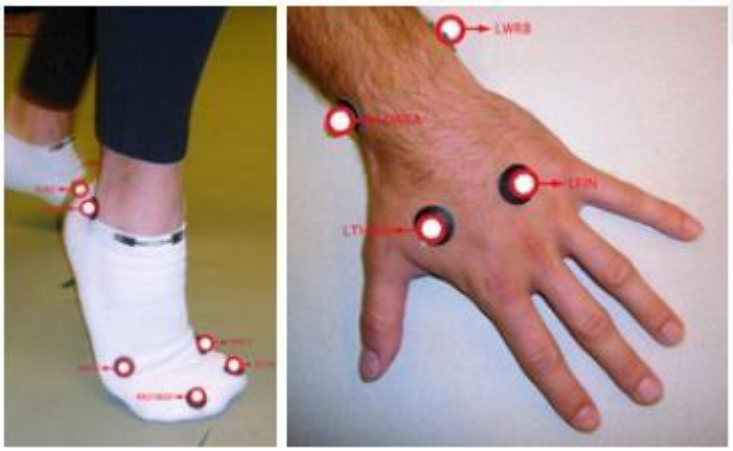
**Şekil 3.9:** Reflektör yürüyüş verilerinin program üzerindeki görüntüsü

12 Vicon marka, 120 Hz , 4 megapiksel çözünürlüğe sahip, infrared MX-40 model kamera düzeni, verilerin toplanması sırasında kullanılmıştır. Kameralar 3m x 8m'lik dikdörtgen bir oda içerisine eşit dağılıma sahip olacak şekilde yerleştirilmişlerdir.

Vücut üzerine yayılan 41 reflektör, kızılötesi kameralar tarafından algılanarak kişinin yürüyüşü 3 boyutlu şekilde çıkarılmaktadır. Verilerin düzenlenmesinde ise 2 farklı yaklaşımın tercih edilme imkânı bulunmaktadır. Marker(İşaretleyici) olan reflektörlerin pozisyonlarının takibi ve çıkarılacak olan iskelet hareketinin takibi. İskelet hareketleri açısal veri sunma olanağına da sahip olsa marker(işaretleyici)'ler hem 41 adet daha fazla veri matrisi içermesi hem de kişinin salınımını daha yüksek seviyede açıklayabilmesi nedeniyle çalışmada tercih edilmiştir.

Çalışmada elde edilen veriler c3d formatında olup, daha sonrasında Cmotion programı sayesinde XML dosya türüne çevrilmiştir ve R2015b Matlab programı versiyonu sayesinde matrisler içerisine atılmıştır. 41 adet reflektörün ayrı X,Y,Z boyutlarındaki tüm veriler yürüyüş sekanslarına bölünmüş ve her bir adımın başlangıcı ve sonu dikkate alınarak adım bazlı inceleme gerçekleştirilmiştir.

Adım bazlı incelemenin yanı sıra bölgesel olarak ta kişilerin belli vücut bölgelerindeki dağılımlar Şekil 3.10'daki gibi çalışma boyunca incelenmiş ve vücut bölgelerinin birbirleriyle olan uyumu saptanmaya çalışılmıştır.



**Şekil 3.10:** El ve ayak bölgelerinde isimlendirilen reflektörlerin gösterimi

Kişilerin tüm vücudunda uyum olabileceği gibi sadece bazı bölgelerinde de aynı şekilde uyumun gerçekleşmesi imkânı bulunmaktadır. Tüm vücudun yanı sıra sadece kalça gibi, baş gibi bazı bölgelerindeki salınımlarında kişilerin cinsiyet ayrımındaki önemi büyük oranda önemlidir. Bu sebeple adım bazlı yürüyüş verilerinin çıkarılmasının akabinde vücut bölgesi bazlı yürüyüş verileri de ayrı olarak tasnif edilmiştir.

En son adımda ise kişilerin adım bazlı yürüyüş verileri bölgesel olarak incelendiğinde bazı konum eksenlerinin öneminin daha fazla olduğu görülmüştür. Örneğin; kişilerin kalça hareketlerinin yatay eksende öneminin düşey veya dikey eksende öneminden daha fazla olduğu görülmüştür. Bu nedenle değişimin cinsiyet ayrımının tespit edilmesinde daha fazla önemi bulunan eksenlerin reflektör konum bilgilerinin de ayrı matrislerde tutulması gerektiği kararlaştırılmış ve uygulanmıştır. Böylece adım bazlı-bölgesel-konum eksen ayrımı dikkate alınarak üçlü bir veri sınıflandırma durumu uygulanmıştır.

## 3.2 YÜRÜYÜŞ ÖZELLİK ÇIKARIMI

Yürüyüş verileri yakalamak için seçilen yöntem sisteminin hedeflerine bağlı olduğunu söyleyebiliriz. Uzaktan tanıma yapılması için, uzak mesafeden veri alabilmeleri için yakalama yöntemlerini geliştirirken, sporcuların yürüyüş için yapılan bir sistem ise verileri yakalamak için giyilebilir sen sörler ve video kamerası kullanabilir. Verileri yakalamak için bir teknik ya da bir kaç teknik aynı anda içerebilir. Eğer verisi alınacak kişi uzak mesafeden çekilecekse video kamerası kullanılır ama diğer uygulamalarda spor gibi bedenin üzerine sensörler kullanılarak ta yapılabilir.

Hatta bu alanda radarlar bile kullanılabilir. Radyo dalgaları ile her bir kişinin yürüyüş tarzı farklı olabileceğinden her biri için radyo dalgaları bile farklı gelir ve böylece sistem onu ayırabilir Ne zaman yürüyüş verileri video şeklinde olursa o zaman bu süreç değerlendirilmeye alınır. Siluette hareket eden nesnesinin videosundan çıkartılan ikili görüntüdür. siluette segmentasyon makine vizyon uygulamasında önemli bir rol oynar, ve ekstra bir avantajı olan sistemin 3d ayrıntılarıyla uğraşmaksızın işlenmesi ve haritalanmasını kayalaştırır, bir de işlenmesi için 3d görüntülerin işlenmesinden daha az bir güç ona yeterlidir. Tanımlama işlemini gerçekleştirmek için sınıflandırıcı kullanılır. Yani kişi izleniyor sonra arka planında ayırma işlemi yapılıyor.

Yürüyüş tanıma yöntemleri iki bölüme ayrılmaktadır model tabanlı yöntem ve modelsiz tabanlı yöntemdir. Model tabanlı yöntem insanın vücudunu modellemeye amaçlayan bir yöntemdir ve maliyetleri yüksektir diğer yöntemlere göre ve performansı daha düşüktür, diğer dediğimiz modelsiz tabanlı yöntem ise kişinin siluet bilgileri kullanarak yüksek performansa sahiptir ve bu başlığın altında kullanılabilecek metot ise (PCA).

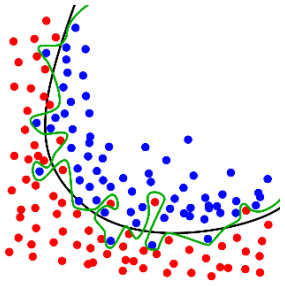
Girdi olarak, yürüyüşün resimleri gait energy image (GEI) olarak gözükmektedir.(GEI) ,yürüyüş siluetin görüntülerin toplamı normal imaj sayısına bölündüğü takdirde. GEI çok etkili ve verimli bir yoldur yürüyüş gösterimi için mesela depolama alanından çok tasarruf etmemesidir ve boşluk ve gürültüye karşı çok hassastır, kamera bir kişi yürürken görüntülerini çeker, çekilmiş görüntülerden GEI'leri elde edebiliriz. Bu GEI imajları sisteme girdi olarak kullanıyoruz.

Yürüyüşten bir özellik çıkartmak için PCA kullanılır. Boyut azaltmada PCA Kabul edilir, özellik seçmek ve özellik çıkarmak iki bölüme ayrılabilir. Sonra son aşama olarak sınıflandırma devreye girer.[19]

## 3.3 YÜRÜME ANALİZİ İÇİN HAFİF EVRİŞİMLİ YAPAY SİNİR AĞI

### 3.3.1. Evrişimli Yapay Sinir Ağları

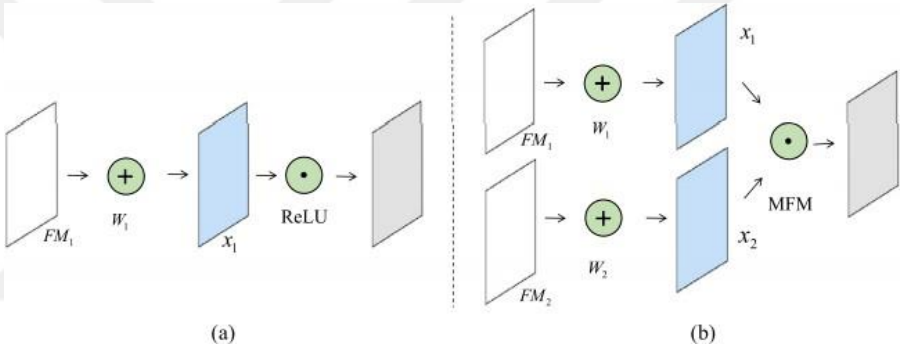
Evrişimli Sinir Ağları, çok katmanlı nöronları içinde barındıran, sınıflandırma ve segmentasyon işlemlerini gerçekleştiren, mimarisinde havuzlama, aktivasyon fonksiyonu, özellik haritaları barındıran bir algoritma yapısıdır. Bu yapıyı oluştururken belirlenen nöron ve katman sayıları ağın karmaşıklığını ve sınıflandırmanın algoritmaya uyumunu önemli ölçüde değiştirebilmektedir. Ağın karmaşıklığının arttırılması sınıflandırma başarısını arttırabileceği gibi yanında depolama ve tahmin hızı sorunlarını da ortaya çıkarabilmektedir. Bunun yanı sıra aşırı uyma sorunları, diğer bir deyişle belirlenen sinir ağı yapısının tezdeki veri kümemize aşırı oranda uyumlu olması, bu sebeple veri kümesinde yer almayan yeni verilere uyum sağlayamaması durumları da oluşabilmektedir (Şekil 3.11). Bu sorunların üzerinden gelinmesi için ağın derinliğinin arttırılmasının sınıflandırmaya yönelik katkısı değerlendirilmelidir. Gereğinden fazla özellik çıkarımının ekstra binlerce özellik yükü oluşturacağı ve bu da performans kaybına neden olacağı göz önünde bulundurulmalıdır.



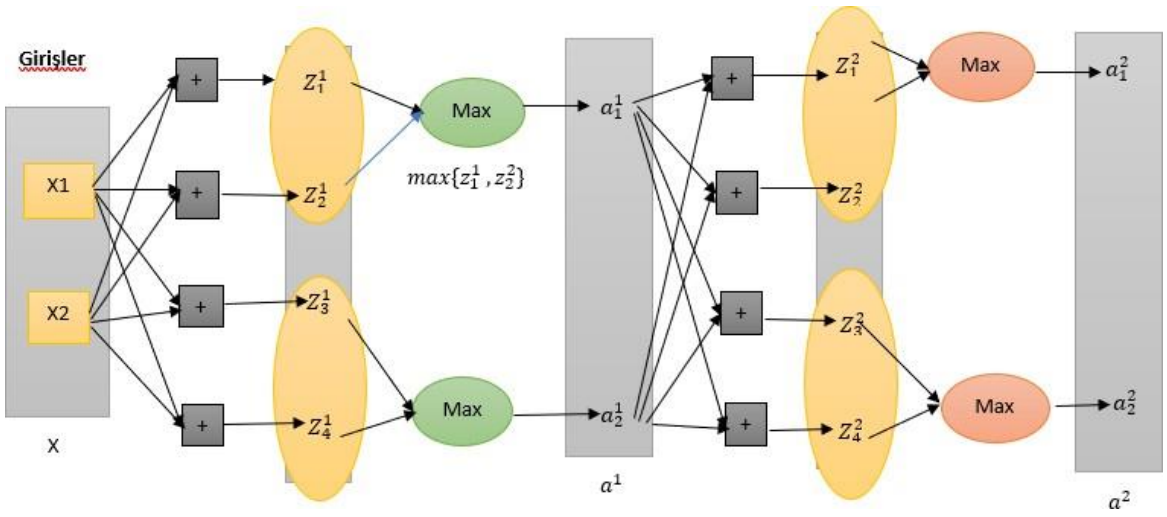
**Şekil 3.11:** Aşırı uyma grafik örneği

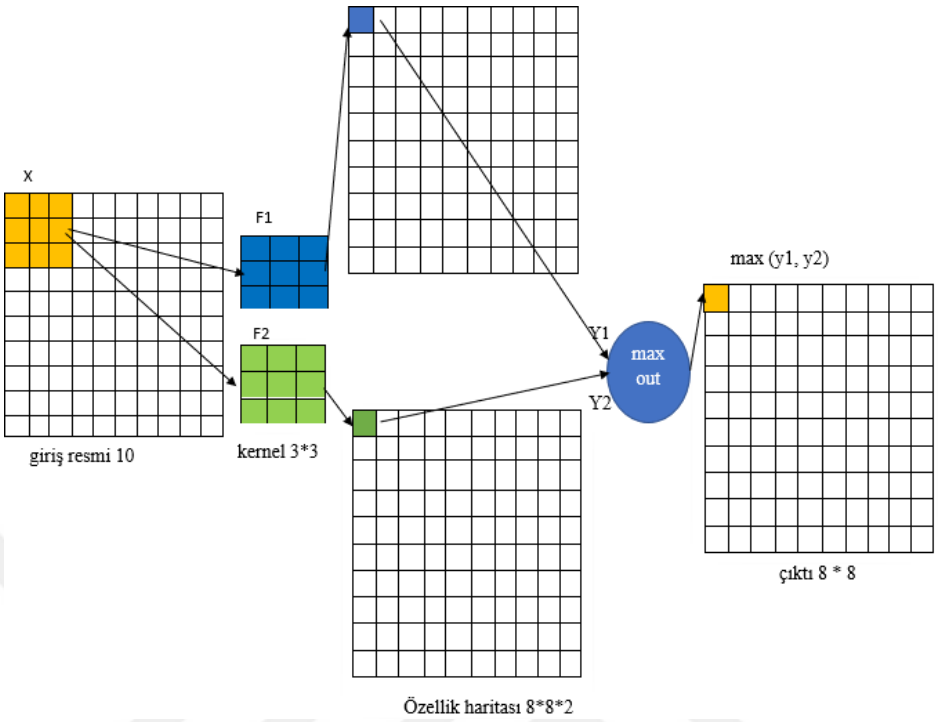
### 3.3.2. Özellik Haritası Filtreleri- MFM (Maksimum-Özellik Haritası)

Özellik çıkarımlarının değerlendirilmesi aşamasında kullanılan bu filtrelerin ana motivasyonu her katmanda bulunan düşük aktivasyon değerlerine sahip nöronların bastırılması olarak düşünülebilir. Bu sayede gürültü özelliklerinin de bastırılması ve bilgi sağlayıcı nöronların etkisinin arttırılması hedeflenmektedir. MFM aktivasyon işlevi (Şekil 3.12-3.13) giriş özelliği haritasını rastgele iki parçaya böler, ardından iki parçanın nöronunu karşılaştırır ve maksimum parçaları bulup seçer. Böylece optimum faydalı özelliklerin ağırlıklarının kaybedilmemesi ve diğer daha düşük seviyeli özelliklerin sınıflandırmada etkisinin azaltılması gerçekleştirilmektedir. Bilgilendirici nöronların sayesinde karmaşıklığın arttırılmadan başarılı sınıflandırma işleminin gerçekleşmesi mümkün olmaktadır.




**Şekil 3.12:** Relu ile MFM arasındaki fark

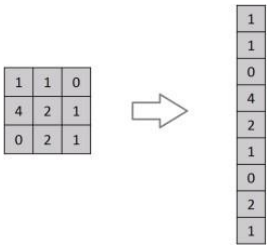





**Şekil 3.13:** Maxout fonksiyonunun işleyişi

### 3.3.3. Düzleştirilmiş Katman

Tam bağlantı katmanından önceki aşama olan bu adımda evrişimsel ve havuzlama katmanından gelen matrixlerin tek boyutlu diziye çevrilmiş hali yer almaktadır (Şekil 3.14). Çünkü genellikle, sinir ağları, giriş verilerini tek boyutlu bir dizilerden almaktadır. Bu sayede verilerimiz tam bağlantı katmanına eşit girdiler olarak verilebilmektedir.




**Şekil 3.14:** Düzleştirilmiş katman çıktısı

### 3.3.4. Maksimum Havuzlama (Pooling Layer)

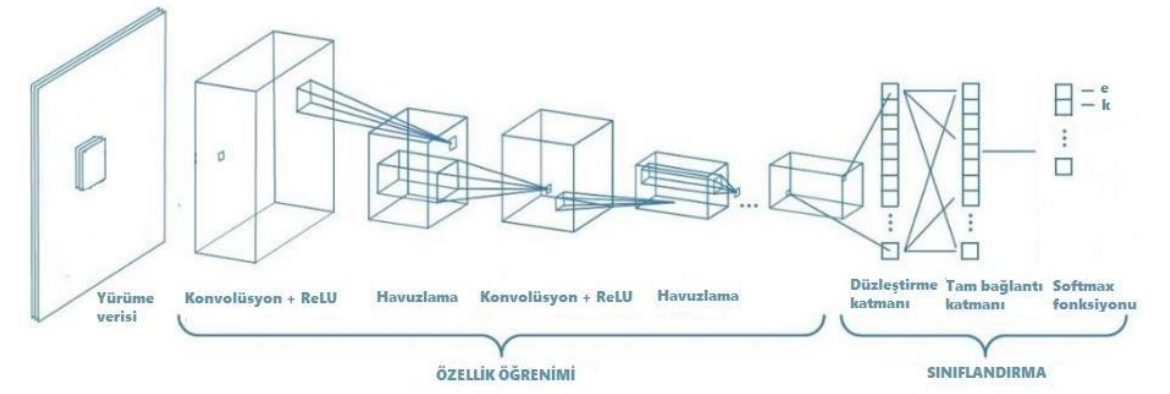
Evrişimsel katmanlar arasında sıklıkla yer alan havuzlama katmanında ağ içindeki parametreleri ve hesaplama sayısını azaltma ve basite indirgeme işlemi yer almaktadır. Bu sayede verilerden bilgi çıkarımı süreci hızlandırılmış olur. Örnek verilecek olursa, maksimum havuzlama katmanına girdi olarak verilen 4x4 boyutundaki matrisimiz (Şekil 3.15), dört eşit kareye bölünerek ve her karede en yüksek sayı seçilerek ikiye indirgenebilir. Böylece her matris çeyreğindeki en büyük sayı sonuç matrisi içerisinde yer almaktadır. Burada kullanılan maksimum yaklaşımındaki temel amaç belirgin ve görünür bir özelliğin gösterilmesi olarak düşünülebilir.

| | | | |
|---|---|---|---|
| 1 | 3 | 2 | 1 |
| 2 | 9 | 1 | 1 |
| 1 | 3 | 2 | 3 |
| 5 | 6 | 1 | 2 |

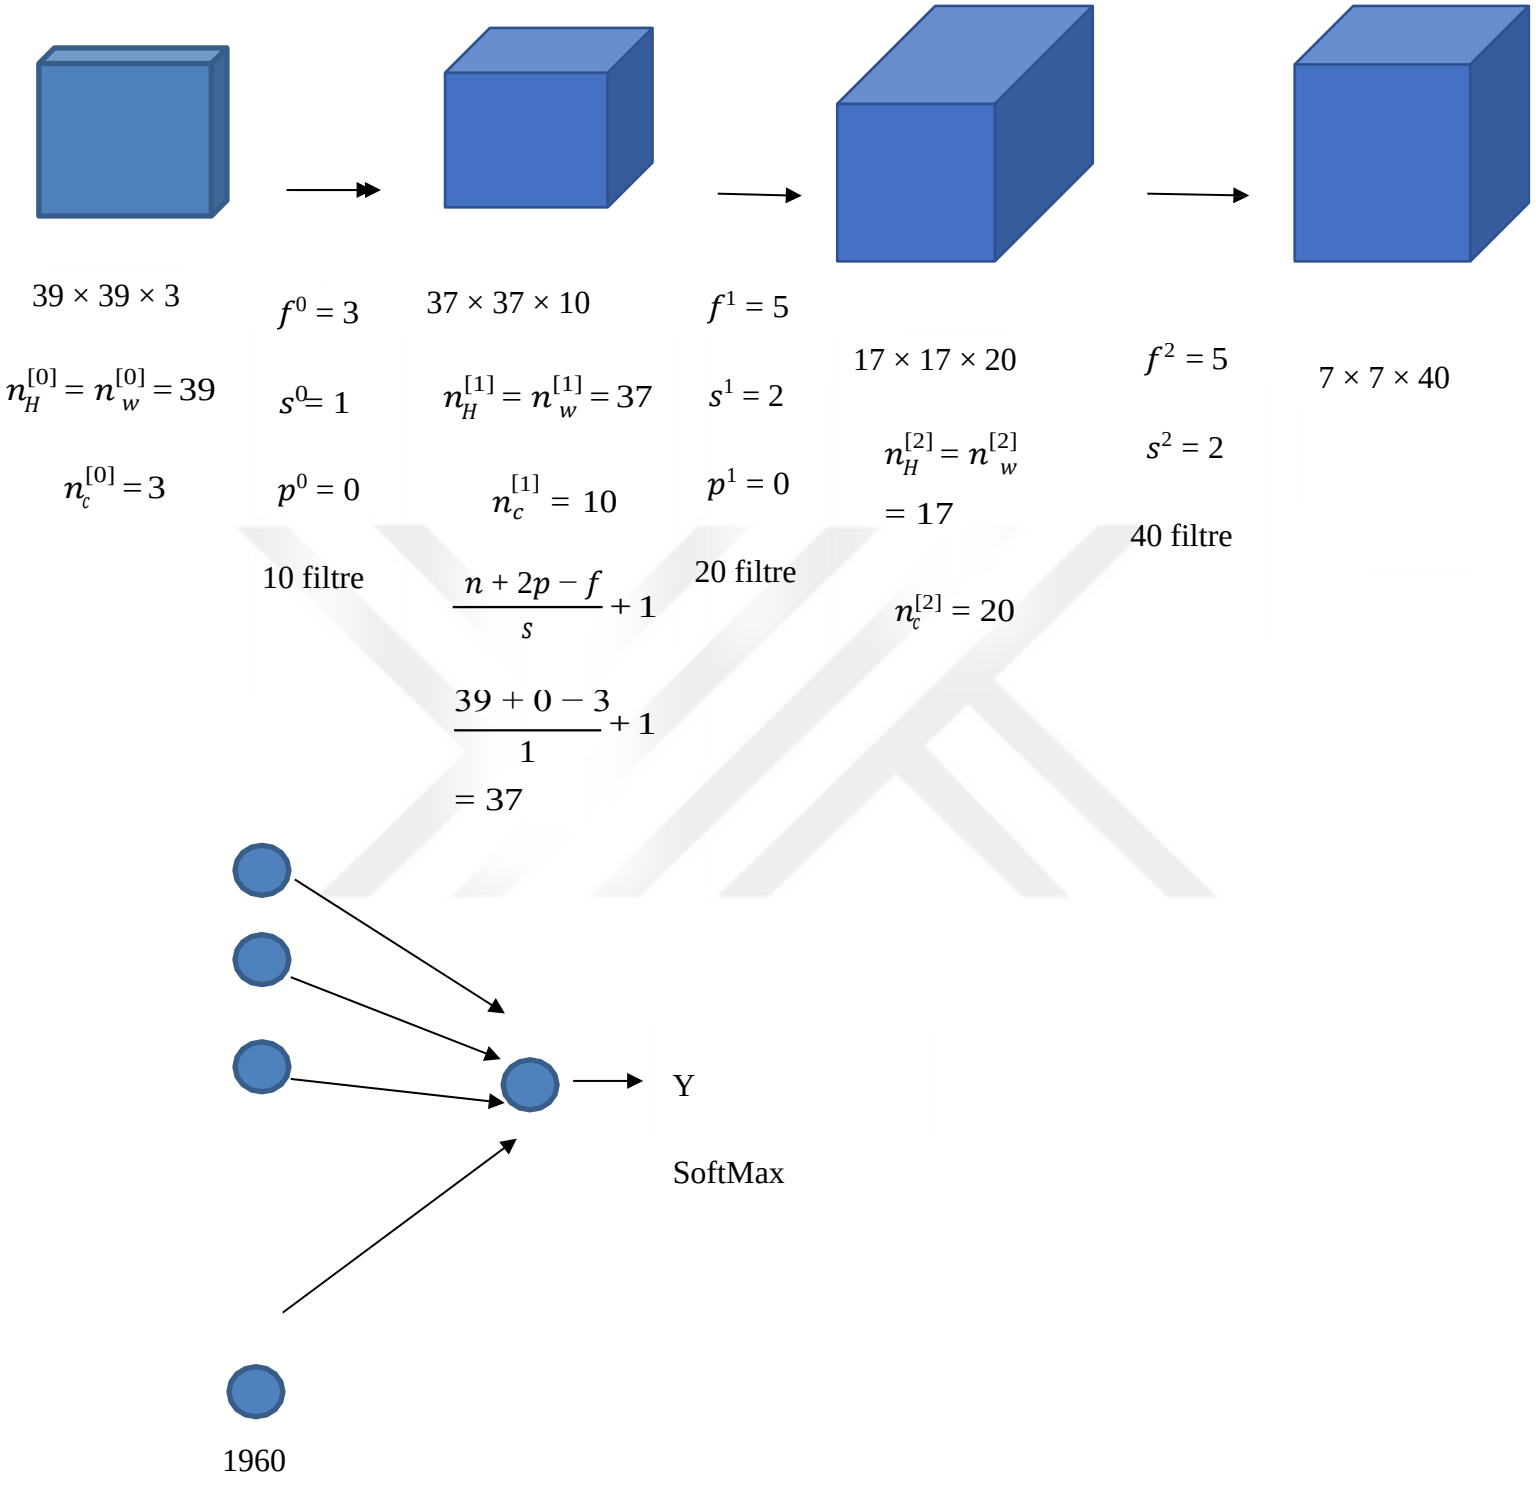
| | | | |
|---|---|---|---|
| 1 | 3 | 2 | 1 |
| 2 | 9 | 1 | 1 |
| 1 | 3 | 2 | 3 |
| 5 | 6 | 1 | 2 |

| | |
|---|---|
| 9 | 2 |
| 6 | 3 |

**Şekil 3.15:** Maksimum havuzlama örneği




**Şekil 3.16:** CNN ağ örneği



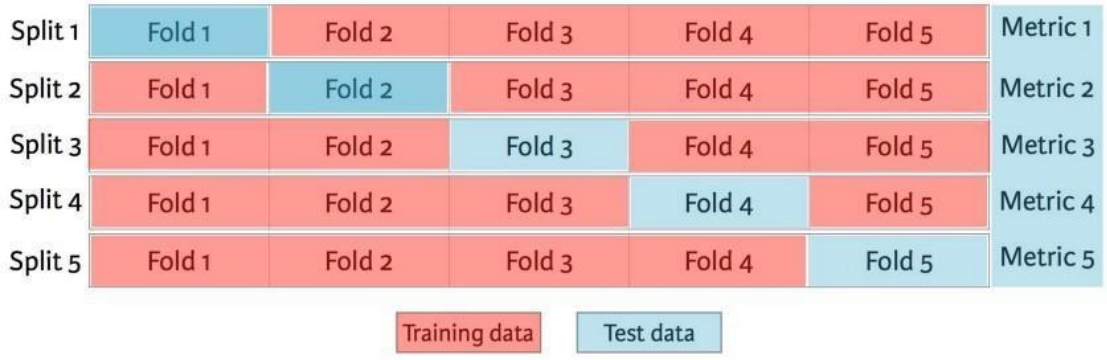

**Şekil 3.17:** Ayrıntılı Gösterilmiş CNN Ağ Örneği

## 3.4 DOĞRULAMA YÖNTEMLERİ

### 3.4.1 Çarpraz doğrulama (Cross-validation)

Bir model doğrulama tekniğidir. Eğittiğimiz modelin amacı doğrultusunda ne kadar düzgün şekilde ilerlediğini,overfitting ve underfitting gibi hatalar olup olmadığını, kontrol etmek için kullanılır.Cross-validation veya "k-fold cross validation", veri kümesinin rastgele 'k' tane gruba ayrılması işlemidir. Gruplardan biri test seti olarak kullanılırken ve geri kalanlar eğitim seti olarak kullanılır. Her bir grup bu şekilde tekrarlanarak model eğitilir ve diğer grup ile test edilir. Bu şekilde model tüm veriler ile eğitilmiş olacaktır ki bu modelin doğruluğu için oldukça gereklidir.

Örnek olarak, 5-fold cross validation için, veri kümesi 5 gruba ayrılır ve model 5 kez eğitilip test edilecektir, böylece her grup test seti olma şansı elde edecektir.




**Şekil 3.18:** Çarpraz doğrulama Örneği

Neden çoğu CNN modeli çapraz doğrulama tekniğini uygulamıyor?

k-kat çapraz doğrulama genellikle birkaç parametreye sahip basit modeller, basit hiperparametreli modeller için kullanılır ve ayrıca modellerin optimize edilmesi kolaydır. Tipik örnekler doğrusal regresyon, lojistik regresyon, küçük sinir ağları ve destek vektör makineleridir. Birçok parametresi olan (örneğin bir milyondan fazla) evrişimli bir sinir ağı için, mimaride çok fazla olası değişikliğe sahibiz. Yapılacak şey, öğrenme oranı, batch boyutu(Model tasarlanırken mini-batch parametresi olarak belirlenen değer; modelin aynı anda kaç veriyi işleyeceği anlamına gelmektedir), dropout (miktar ve konum) ile bazı deneyler yapmaktır. Evrişimli bir sinir ağını cok buyuk bir veri kümesiyle eğitmek oldukça uzun zaman

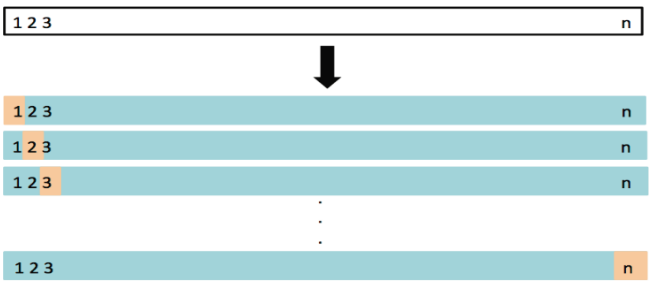
alır. Hiperparametre optimizasyonu yapmak tamamen aşırı olur. makalelerde, diğer araştırma makalelerinin sonuçlarını iyileştirmeye çalışırlar. Hedef, seçilen hiperparametreleri iyileştirerek daha iyi sonuçlar elde etmek değil, verilen görevi çözmek için yeni fikirler üretmektir, ancak daha iyi doğruluk veya daha az hesaplama çabası ile gerçekleştirmektir.

### 3.4.2 Hold-out

Hold-out, verisetini "eğitim" ve "test" kümesi olarak ikiye ayırma yöntemidir. Eğitim seti, modelin eğitildiği verilerden test seti, modelin eğitilmeyen veriler üzerinde ne kadar iyi performans gösterdiğini görmek için kullanılan verilerdir. Hold-out yöntemini kullanırken yaygın olarak, eğitim için verilerin% 80'ini ve test için kalan verilerin% 20'sini kullanmaktadır. Tabi bu oran veri setinin boyutu ile değişmektedir. Eğer çok büyük verisetiniz var ise %20 test yerine %1 bile yeterli olacaktır.

### 3.4.3 Birisi Dışarıda Çapraz Doğrulama Yöntemi (Leave-One-Out Cross-Validation)

Birisi Dışarıda Çapraz Doğrulama Yöntemi çalışmamızda da kullanılan yöntemdir,Birisi dışarıda çapraz doğrulama yönteminde, n adet örneğin bulunduğu veri setinde, veri seti n parçaya bölünür. n parçaya bölunmuş veri setinde her seferinde sadece bir örnek dışarıda kalacak şekilde kalan tüm veri seti (n-1) ile sınıflandırıcı eğitilir ve bu işlem tüm örnekler için tekrarlanır. Bu şekilde elde edilen 83 adet hatanın ortalaması ile sınıflandırıcı performansı tahmin edilmiş olur. Gerçekte örnek sayısı kadar k parçaya ayrılan k-Parçalı Çapraz Doğrulama Yöntemi gibi düşünülebilir, genellikle verinin sinifin bulunmasi zor olan tibbi tani uygulamalarda kullanilmaktadir.

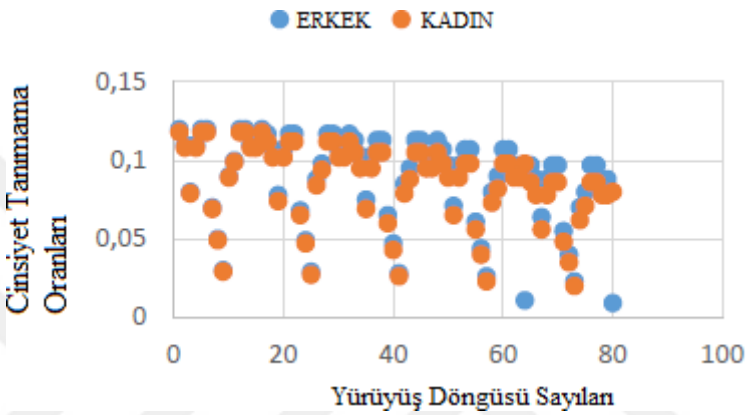



**Şekil 3.19:** Birisi Dışarıda Çapraz Doğrulama Yöntemi Örneği

# 4. BULGULAR

Bu kısımda çalışmamızda yer alan yürüyüş analizinde cinsiyet tanıma sonuçları, bu sonuçların diğer çalışmalarla karşılaştırılması ve performans analizi başlıkları ile çalışmanın bulguları incelenecektir.

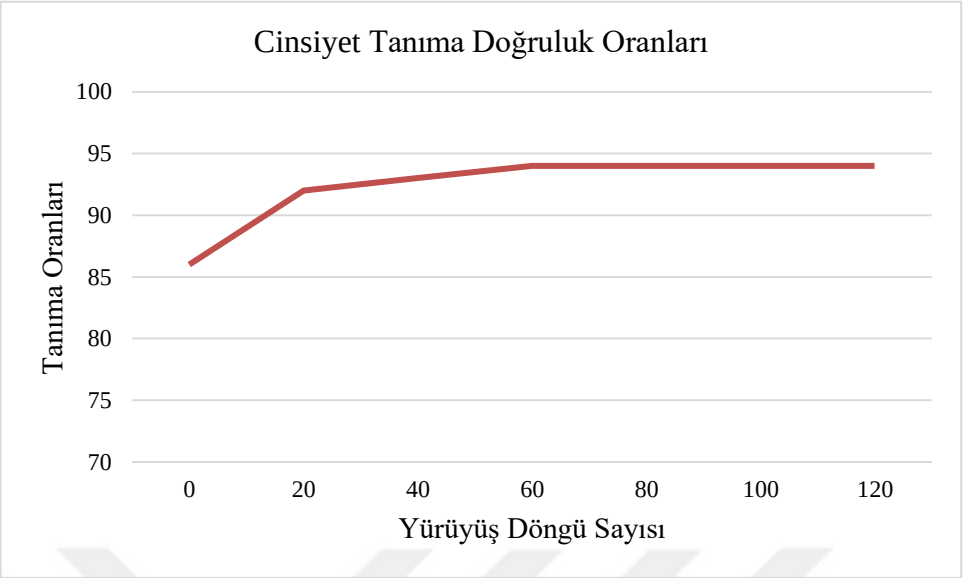
## 4.1. CİNSİYET TANIMA SONUÇLARI




**Şekil 4.1:** Erkek-Kadın Yürüyüş Analizinde Cinsiyet Tanımama Oranları

Çalışmamızda yürüyüş analizi başlangıcındaki ilk yürüyüş döngülerinde cinsiyet tanıma oranının daha düşük olduğu ve yürüyüşün ilerlemesi ile beraber sonraki gelen yürüyüş döngülerinde yürüyüş karakterinin daha sağlam oluştuğu ve bu nedenle yürüyüş cinsiyet tanıma oranının daha yüksek olduğu Şekil 4.1' te görüldüğü üzeredir. Son yürüyüş döngülerinde cinsiyet tanıma oranının ilk yürüyüş döngülerine göre %1'lik pozitif orana sahiptir. Bu farkın, yürüme sekansı süresinin arttığı zaman daha da artacağı düşünülmektedir. Buna sebep olarak, yürüyüş karakteristiğinin daha iyi gerçekleşmesi olduğu düşünülmektedir

Bunun yanı sıra çalışmamızın bulgularından biri de kadınların yürüyüş analizinden cinsiyet saptanma skorlarının daha yüksek olmasıdır. Buna neden olarak ise cinsiyetin tespitinde faydalanılan ayırt edici özelliklerin kadınların yürüyüşünde daha belirgin şekilde yer almalarıdır. Tüm yürüyüş örneklerinden elde edilen sonuçlarda ise %92.7'lik bir ayırt etme oranına ulaşıldığı görülmüştür. En yüksek başarı ise uzun kadın yürüyüşünden oluşan örneklerdir. Bu örnekler tüm cinsiyet tanıma skorlarından %3 oranında daha pozitif sonuç elde etmiştir.

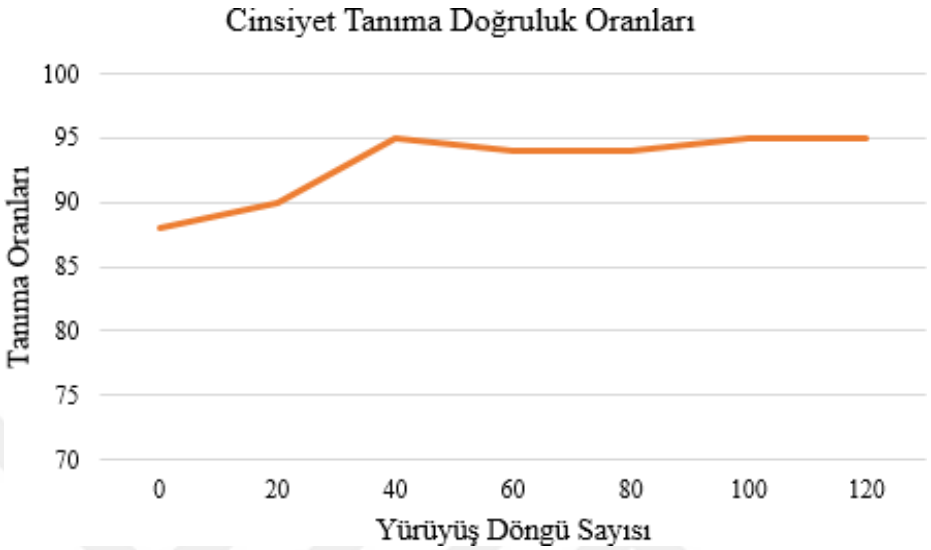



**Şekil 4.2:** Algoritmamiza göre tanıma oranları yürüyüş döngü sayısıyla değişmesi

| İsim | Tür | Filter ölçü/stride,pad | Çıkış ölçü |
|---|---|---|---|
| Giriş | - | - | 128*128 *3 |
| Conv1<br>Mfm1 | Convolution<br>MFM | 7 * 7/3,2<br>- | 126 * 126 * 96<br>126 * 126 * 48 |
| Max – Pool1 | Pooling | 2 *2/2 | 63 * 63 * 48 |
| Conv2a<br>Mfm2a<br>Conv2<br>Mfm2 | Convolution<br>MFM<br>Convolution<br>MFM | 1 * 1/1<br>-<br>3 * 3/1,1<br>- | 63 * 63 * 120<br>63 * 63 * 60<br>63 * 63 * 180<br>63 * 63 * 90 |
| Max – Pool2 | Max pooling | 2 *2/2 | 32 * 32 * 90 |
| Conv3a<br>Mfm3a<br>Conv3<br><br>MFM3 | Convolution<br>Convolution<br>MFM<br><br> | 1 * 1/1<br>-<br>3 * 3/1,1<br><br>- | 32 * 32 * 200<br>32 * 32 * 100<br>32 * 32* 128<br><br>32 * 32 * 128 |
| Max-Pool 2<br>FC1 | Max pooling | 2 * 2/2 | 16 * 16 * 128<br>512 |
| MFM5<br>FC2 | Fully connected | | 256<br>25945 |

**Tablo 4.1:** Algoritmanın parametreleri adım adım belirleyerek

**Eğer parametreleri aşağıdaki gibi değiştirecek olursak bu şekilde:**




**Şekil 4.3:** Algoritmamizdaki parametreleri değiştirerek tanıma oranları yürüyüş döngü sayısıyla değişmesi

| İsim | Tür | Filter ölçü/stride,pad | Çıkış ölçü | aktivasyon boyutu | Parametre sayisi |
|---|---|---|---|---|---|
| Giriş | - | - | 128 *128 *3 | | |
| Conv1<br>Mfm1 | Convolution<br>MFM | 5 * 5/1,2<br>- | 128 * 128 * 96<br>128 * 128 * 48 | 1572K<br>786K | 7296<br>- |
| Max – Pool1 | Pooling | 2 *2/2 | 64 * 64 * 48 | 190512 | - |
| Conv2a<br>Mfm2a<br>Conv2<br>Mfm2 | Convolution<br>MFM<br>Convolution<br>MFM | 1 * 1/1<br>-<br>3 * 3/1,1<br>- | 64 * 64 * 120<br>64 * 64 * 60<br>64 * 64 * 180<br>63 *63 * 90 | 491K<br>-<br>714420 | 23593K<br>-<br>97380 |
| Max – Pool2 | Max pooling | 2 *2/2 | 32 * 32 * 90 | | |
| Conv3a<br>Mfm3a<br>Conv3<br><br>MFM3 | Convolution<br>MFM<br>Convolution<br><br> | 1 * 1/1<br>-<br>3 * 3/1,1<br><br>- | 32 * 32 * 200<br>32 * 32 * 100<br>32 * 32* 256<br><br>32 * 32 * 128 | 204800<br><br>262144 | 184k<br><br>26214K |
| Max-Pool 2 | Max pooling | 2 * 2/2 | 16 * 16 * 128 | | |

| | | | | | |
|---|---|---|---|---|---|
| FC1 | | | 512 | | 16M |
| MFM5<br>FC2 | Fully<br>connected | | 256<br>10575 | | 131 K |

**Tablo 4.2:** Algoritmanın parametreleri değiştirerek adım adım belirleyerek akışı

## 4.2. LİTERATÜR SONUÇLARI İLE KARŞILAŞTIRMA

| Metotlar | Tanımlama Skorları (%) |
|---|---|
| Lee ve Grimson [27] | 85 |
| Huang ve Wang [28] | 89.5 |
| Li ve ark. [29] | 93.28 |
| Chen ve ark. [30] | 93.28 |
| Önerilen Yaklaşım | 92.7 |

**Tablo 4.3:** Sonuçlar arasında karşılaştırma

Literatürde yer alan çalışmalardan (Tablo 4.3) ilk olarak Lee ve Grimson [27]'un çalışmamızda da yararlandığımız SVM (Support Vector Machines) metodu kullanılarak yapılan çalışmasına bakacak olursak cinsiyet ayrımında %85'lik bir başarı oranı yakaladıkları görülmektedir. Bu çalışmalarında ortogonal yürüyüş görüntülerinden ortalama 57 özellik çıkarımı gerçekleştirerek bu skorları elde etmişlerdir. Huang ve ark. [28] ise, yürüyüşlerin füzyonu ile oluşturdukları çalışmalarında %89.5'lik bir başarı oranını yakalamışlardır. Li ve ark. [29] yürüyüş analizinde cinsiyet tanımaya katkıda bulunanların önemlerini yakaladıkları çalışmalarında %93'lük bir başarı oranına erişmişlerdir. Bu çalışmalarında ayakların hareketlerinin ayırt etmeye öneminin tam saptanamadığı, ayağın arka-geri hareketiyle baş hareketlerinin de bu süreçte çok yardımcı olmadığını belirtmişlerdir. Gövde hareketlerinin ise katkısının önemli derecede olduğunu belirtmişlerdir. Aynı şekilde bizim çalışmamızda da kol ve gövde hareketlerinin ayırt etmeye önemli katkısı tespit edilmiştir. Daha sonra gelen baş ve ileri yönlü bacak hareketleri ve en sonda da ayak ve geri yönlü bacak hareketleri yer almıştır. Chen ve ark. [30] önerdiği yöntemde ise en optimal düşük boyutlu alt özellik kümesinin çıkartılması ve bununda yapılması sırasında en az insan desteği alınması ve böylece günlük yaşamda yüksek kullanım imkanının sağlanmasını hedeflemişlerdir. Yalnız bu süreçte %93'lük yüksek başarı oranını yakalamış olsalarda işlem süresinin yüksek olması durumuna değinmişlerdir ve bu sürenin iyileştirilmesine ihtiyaç duyulduğunu belirtmişlerdir.

Tüm bu çalışmalarda görüldüğü üzere cinsiyet ayrımında yürüyüş analizinin başarı oranının yüzde 90'nın üzerinde olması çalışmanın başarısı açısından oldukça önemlidir. Bunun altında kalan çalışmalar bulunmasına rağmen genellikle hedefler bu rakamın üzerinde yer almaktadır. Üstelik 2 boyutlu veriden 3 boyutlu veriye geçiş sırasında oluşacak standart olmayan veri karmaşıklığına rağmen yine de cinsiyet tanıma yüzdelik değerimizin bu rakamın üzerinde kalması çalışmamızın başarısı açısından faydalı bir parametredir. Bunun yanı sıra çalışmamızda kullanılan hafifletilmiş yapay sinir ağı hem işlemin geçen süresinin hızlılığı bakımından diğer çalışmalara üstünlük sağlamamızı hem de işlemci kapasitemizin minimum düzeyde kullanılarak yine diğer çalışmalara göre avantajlı olmamızı sağlamıştır. Bu sayede yüksek tanıma skorunun yanı sıra, çalışmanın düşük işlemci gereksinimi, hızlı çalışma kapasitesi gibi diğer avantajlarının da ön plana çıkmasını sağlamıştır.

## 4.3. PERFORMANS ANALİZİ

Tez çalışmasında kullanılan Light CNN yaklaşımının (Hafifletilmiş Yapay Sinir Ağları) karışık, iç içe gömülü, yüksek gürültü boyutuna sahip olabilen büyük boyutlu verilerde başarılı bir şekilde uygulanabildiği çalışmada elde edilen yüksek tespit oranıyla beraber açık bir şekilde görülmüştür. Yüksek saptama oranının da yanında hesaplama maliyeti ve gerek havuzlama gerek MFM yaklaşımıyla depolama alanındaki verimlilik durumları da performans üzerindeki olumlu etkenlerdir. Light CNN mimarisinde yer alan MFM, küçük konvolüsyon filtreleri ve NIN (Network in Network) metodu performansın arttırılması ve hesaplama-depolama maliyetlerinin düşürülmesi amacıyla tasarlanmıştır. Performans analizi kapsamındaki 3 gösterge bu çalışmada gerçekleştirilen performans değerlendirme kriterleri olmuştur:

1) Bu tezde ReLU eşikleme kriteri yerine kullanılan MFM işlemi daha az parametre ile öğrenim gerçekleştirme olanağı ortaya çıkarmıştır. Ayrıca bu yöntem daha rekabetçi bir ilişki yaklaşımı ile daha iyi bir genelleme yeteneği kazandırmıştır.
2) Önceden eğitilmiş derin ağ ile yapılan anlamsal önyükleme sayesinde gürültülü verilerle daha iyi bir sınıflandırma imkanı doğmuştur. İstenilen düzeyde tutarlı olmayan etiketler tahminleme olasılıklarıyla ya yeniden etiketlenmiş ya da etiket tamamıyla eğitimden kaldırılmıştır.

3) Heterojen yapıda karıştırılmış verilere rağmen tutarlı eğitim ve modelleme sayesinde sınıflandırma başarı oranının radikal değişikliklere uğramadığı ve bu sayede farklı yürüyüş veritabanlarına karşı sistemin dayanıklı olacağı düşünülmektedir.

Tez için planlanan mimariye bakılacak olursa (Tablo 4.4);

| **lightCNN_MFM** |
|---|
| Input(3D Gait Reflectors Coordinates) |
| Conv. |
| MFM |
| Conv. |
| MFM |
| max-pooling |
| Conv. |
| MFM |
| Conv. |
| MFM |
| max-pooling |
| FC1 |
| MFM |
| FC2 |

**Tablo 4.4:** Light CNN Mimari Yaklaşımı

Konvolüsyon işleminden sonra uygulanan MFM ile beraber katmanlar arasında özellik seçimi işlemi gerçekleştirilmiş ve parametre sayıları da küçük boyutlu konvolüsyon çekirdekçikleriyle azaltılmıştır. Az katman kullanımının sebebi katman sayısının artmasıyla hızlı bir şekilde artan işlem yükü olduğudur. Ayrıca FC ile belirtilen Fully Conntected Layers (Tam Bağlantı Katmanları), global ortalama havuzlama katmanı yerine başarı performansı dikkate alınarak tercih edilmiştir. Bunun sebebi olarak ise, bu yöntem tercih edildiği zaman, eğitim aşamasında, özellik haritalarında bulunan hem anlamsal hem de boyutsal bilgilerin zarar görebilme ihtimalidir.

Son olarak ise anlamsal önyükleme ile beraber “kendi-kendine eğitim” gerçekleşmiş, bu sayede daha basit ve etkili bir örnek dağılım hesaplaması gerçekleştirilmiştir. Standart hataların hesaplanması ve güven aralıklarının belirlenmesinin daha karışık veri dağılımında bile daha

başarılı bir şekilde gerçekleşmesi sağlanmıştır, bu da hesaplama istikrarının kontrolündeki performansı daha yukarıya taşımıştır.

# TARTIŞMA VE SONUÇ

Bu çalışmada, cinsiyet tanımlaması işleminin yürüyüş özelliklerinden faydalanılarak gerçekleştirilmesi planlanmış, özellik çıkarımı ve boyut azaltımı için geleneksel PCA (Principal Component Analysis) yönteminden faydalanılmış ve bu özellikler Light CNN (Hafifletilmiş Yapay Sinir Ağları) yardımıyla sınıflandırılmıştır. 3 Boyutlu sabit, tek yönlü, normalize edilmiş işaret kümeleri (marker set)'nden oluşan yürüyüş örnekleri kaynak veri seti olarak kullanılmıştır. Böylelikle hem yürüyüş seti hem de hesaplama işlemlerinde işlem karmaşıklığı seviyesi düşürülmüştür. Bu sayede hesaplama ve depolama açısından literatürde yer alan çalışmalara üstünlük sağlanması gerçekleştirilmiştir. Çalışmanın sonuçları bakımından incelenecek olursa, %92,7'lik bir cinsiyet tanımlama başarısı, ayrıca bayan yürüyüş örneklerinde bu oranın daha yüksek olması, şaşırtabilirlik seviyesinin ise (False Negative - True Negative) %4'ün altında kalması önem arz etmektedir. Ayrıca cinsiyet tanımlama oranında yürüyüş sekansı sonundaki adımların başlangıç aşamasındaki adımlardan %1'e yakın daha yüksek başarı göstermesi yürüyüş ritminin yakalandığından daha ayırt edilebilir oluğunu ortaya koymaktadır.

Çalışmanın başka bulgularından biri ise bayan yürüyüş örneklerindeki ayırt edici özelliklerin erkek yürüyüş örneklerinden daha belirgin olması, sayısının daha fazla olması, bunun sonucu olarak daha yüksek cinsiyet tanımlama başarısı göstermesi olmuştur. Bu sayede cinsiyetler arası eşit olmayan durum tespit edilmiş, daha derin araştırmalar için bayan yürüyüşlerinden yeni ayırt edilebilir özelliklerin çıkarılabileceği, bu sayede başarı oranının farklı algoritmik yaklaşımlarla gelecek çalışmalarda arttırılabileceği anlaşılmıştır.

Bunun yanı sıra karmaşıklığı arttırılmamış, daha az katmanlı olarak planlanan hafifletilmiş yapay sinir ağımıza alternatif olarak başka oluşturulacak yapılar ile cinsiyet tanımlama sonuçlarının iyileştirilebileceği, ve böylece ileriki çalışmalarda bunun değerlendirilebileceği düşünülmüştür. Yürüyüş özellikleri çıkarımı aşamasında da varyansı daha yüksek ve durumsal olarak değişmez özelliklerin tespiti ile bu başarı skorunun arttırılması mümkün gözükmektedir.

Son olarak bu çalışma biyometrik yürüyüş özelliğinin, yakın temas durumu mümkün olmayan, diğer klasik biyometrik ayırt etme metotların çalışmasının mümkün olmadığı durumlarda faydalı bir şekilde cinsiyet tanımlama durumlarında kullanılabileceği ortaya konulmuştur.

# KAYNAKLAR

[1] Souhail Guennouni,Anass Mansouri and Ali Ahaitouf,Biometric Systems and Their Application,submitted: October 19th 2018 Reviewed:Junuary 30 th 2019 published:March 1 st 2019

[2] Jitendra Choudhary,Asst.Prof.Computer Science & Engineering Department,IES College Bhopal, India,Vol.2,issue. 5,Sep,-Oct 2012 pp-3150-3155

[3] Biyometrik güvenlik sistemleri, Rüya Şamlı, M. Erkan Yüksel, İstanbul Üniversitesi Bilgisayar Mühendisliği, Avcılar, İstanbul

[4] Khalil Khan, Muhammad Attique, Ikram Syed,Asma Gül ,Automatic Gender Classification Through Face Segmentation,6 june 2019

[5] Feng lin,Yingxiao wu,Yan Zhuang,Xi Long,Wenyao Xu"Human Gender Classification: A Review",International journal of biometrics,

[6] Mansour Alsulaiman,Zulfikar Ali,Ghulam Muhammad ,Gender Classification with Vioce Intensity,16-18 Nov. 2011.

[7] Zhihuai Xie,Zhenhua,Chengshan Qian ,Palmprint gender classification by convolutional neural network,28 may 2018

[8] M. S. Nixon and J. N. Carter, "Automatic Recognition by Gait," in *Proceedings of the IEEE*, vol. 94, no. 11, pp. 2013-2024, Nov. 2006, doi: 10.1109/JPROC.2006.886018.

[9] D. A. Winter, "Biomechanical motor patterns in normal walking," Journal of motor behavior, vol. 15, no. 4, pp. 302–330, 1983.

[10] J. Wang, M. She, S. Nahavandi, and A. Kouzani, "A review of vision-based gait recognition methods for human identification," in Digital Image Computing: Techniques and Applications (DICTA), 2010 International Conference on. IEEE, 2010, pp. 320–327

[11] M. S. Nixon and J. N. Carter, "Automatic recognition by gait," Proceedings of the IEEE, vol. 94, no. 11, pp. 2013–2024, 2006.

[12] S. Cheung and C. Kamath, “Robust background subtraction with foreground validation for urban traffic video,” EURASIP Journal on Applied Signal Processing, vol. 2005, pp. 2330–2340, 2005.

[13] S. Denman, M. Halstead, A. Bialkowski, C. B. Fookes, and S. Sridharan, “Can you describe him for me? a technique for semantic person search in video,” Proceedings of Digital Image Computing: Techniques and Applications 2012, pp. 1–8, 2012.

[14] S. Denman, C. Fookes, S. Sridharan, and D. Ryan, “Multi-modal object tracking using dynamic performance metrics,” in Advanced Video and Signal Based Surveillance (AVSS), 2010 Seventh IEEE International Conference on. IEEE, 2010, pp. 286–293.

[15] D. Ryan, S. Denman, C. Fookes, and S. Sridharan, “Textures of optical flow for real-time anomaly detection in crowds,” in Advanced Video and Signal-Based Surveillance (AVSS), 2011 8th IEEE International Conference on. IEEE, 2011, pp. 230–235.

[16] S. Denman, C. Fookes, and S. Sridharan, “Improved simultaneous computation of motion detection and optical flow for object tracking,” in Digital Image Computing: Techniques and Applications, 2009. DICTA’09. IEEE, 2009, pp. 175–182.

[17] Ian J. Goodfellow goodfeli@iro.umontreal.ca David Warde-Farley wardefar@iro.umontreal.ca Mehdi Mirza mirzamom@iro.umontreal.ca Aaron Courville aaron.courville@umontreal.ca Yoshua Bengio yoshua.bengio@umontreal.ca D´epartement d’Informatique et de Recherche Op´erationelle, Universit´e de Montr´eal 2920, chemin de la Tour, Montr´eal, Qu´ebec, Canada, H3T 1J8

[18] Light CNN For Deep Face Representation Using Multilevel Residual Networks Kiran Singla1 , Prakash Mohod2

[19] A Light CNN for Deep Face Representation with Noisy Labels Xiang Wu, Ran He, Zhenan Sun, Tieniu Tan

[20] Learning Robust Deep Face Representation Xiang Wu University of Science and Technology Beijing Beijing, China alfredxiangwu@gmail.cm

[21] A Comprehensive Study on Cross-View Gait Based Human Identification with Deep CNNs Zifeng Wu, Yongzhen Huang, Liang Wang, Xiaogang Wang, and Tieniu Tan

[22] Biometric Gait Recognition Jeffrey E. Boyd1 and James J. Little2 1 Department of Computer Science University of Calgary boyd@cpsc.ucalgary.ca 2 Department of Computer Science University of British Columbia little@cs.ubc.ca

[23] By Maria de Fatima Domingues, Catia Tavares,Tiago Leite,Nelia Alberto,Catia Leitao, Carlos Marques,Ayman Radwan,Eduardo Rocon,Paulo Antunes and Paulo Andre,Fiber Bragg Gratings as e-Health Enablers: An Overview for gait Analysis Applications,published:November 5 th 2018

[24] Lin, F., Wu, Y., Zhuang, Y., Long, X., & Xu, W. (2016). Human gender classification: a review.InternationalJournalof Biometrics,8(3/4),275-300.

[25] Background Subtraction Shashank Dhariwal Manmeet Singh Kapoor ,Adham Beyki

[26] Mayur Popade , Anita Thengade,Human Gait Recognition Based On Gait Energy Image,Impact Factor(2015)

[27] L. Lee and W. E. L. Grimson, "Gait analysis for recognition and classification," *Proceedings of Fifth IEEE International Conference on Automatic Face Gesture Recognition*, Washington, DC, USA, 2002, pp. 155-162, doi: 10.1109/AFGR.2002.1004148.

[28] Wu Z, Huang Y, Wang L, Wang X, Tan T. A Comprehensive Study on Cross-View Gait Based Human Identification with Deep CNNs. IEEE Trans Pattern Anal Mach Intell. 2017 Feb;39(2):209-226. doi: 10.1109/TPAMI.2016.2545669. Epub 2016 Mar 23. PMID: 27019478.

[29] Model-Based Human Gait Recognition Via Deterministic Learning August 2012Neural networks: the official journal of the International Neural Network Society 35(2):92-102 DOI: 10.1016/j.neunet.2012.07.012

[30] Jinyan Chen, Gait Correlation Analysis Based Human Identification ScientificWorldJournal. 2014; 2014: 168275. Published online 2014 Jan 29. doi: