



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

**FARKLI TRANSFER ÖĞRENME YÖNTEMLERİNİN
KARŞILAŞTIRILMASI İLE GÖZ ÇEVRESİ
GÖRÜNTÜLERİNDEN KİŞİ TANIMA**

Yasr Mahdi HAMA RASHID

YÜKSEK LİSANS TEZİ

KIRŞEHİR / 2022



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

**FARKLI TRANSFER ÖĞRENME YÖNTEMLERİNİN
KARŞILAŞTIRILMASI İLE GÖZ ÇEVRESİ
GÖRÜNTÜLERİNDEN KİŞİ TANIMA**

Yasr Mahdi HAMA RASHID

YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Emrah AYDEMİR

İKİNCİ DANIŞMAN
Dr. Öğr. Üyesi Cemal AKTÜRK

KIRŞEHİR / 2022

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.

Yasr Mahdi HAMA RASHID



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 Doç. Dr. Emrah AYDEMİR'e teşekkür ederim. Çalışmalarım boyunca maddi manevi destekleriyle beni hiçbir zaman yalnız bırakmayan, beni bugünlere getiren aileme de sonsuz teşekkürler ederim.

Ekim, 2022

Yasr Mahdi HAMA RASHID

İÇİNDEKİLER

Sayfa No

TEZ BİLDİRİMİ	ii
ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ	ix
ÖZET	x
ABSTRACT	xii
1. GİRİŞ	1
1.1. Gözün Anatomik Yapısı	4
1.2. Amaç ve Önem.....	7
1.3. Yapılan Çalışmalar	8
2. MATERYAL VE YÖNTEM.....	13
2.1. Verilerin Toplanması	13
2.2. Verilerin Analizi	14
2.3. Eğitim ve Test Verilerinin Ayrıştırılması	16
2.4. Başarı Ölçütleri	17
3. TRANSFER ÖĞRENME	19
3.1.1. AlexNet	22
3.1.2. VGG (Visual Geometry Group).....	22
3.1.3. ResNet.....	22
3.1.4. DenseNet.....	23
3.1.5. EfficientNet	23
3.1.6. Inception-V3	23
3.1.7. MobileNet.....	23
3.1.8. Xception	24
3.1.9. NasNet	24
4. BULGULAR	25
4.1. İstatistiksel Bulgular	25
4.2. Kişi Sınıflandırma Bulguları.....	26
4.3. Cinsiyet Sınıflandırma Bulguları.....	29

4.4. Yaş Sınıflandırma Bulguları	33
5. TARTIŞMA VE SONUÇ.....	37
KAYNAKLAR.....	40
ÖZGEÇMİŞ.....	43



ŞEKİL LİSTESİ

	Sayfa No
Şekil 1.1. Gözün anatomik yapısı [9].....	5
Şekil 2.1. Örnek göz çevresi görüntüleri	13
Şekil 2.2. Göz çevresi görüntülerine toplu bir bakış	14
Şekil 3.1. Transfer Öğrenme Model Yapısı	21
Şekil 3.2. AlexNet Convolutional Neural Network Layer Structure [38].....	22
Şekil 4.1. Her bir yaştan kaç görüntü olduğunu gösteren grafik.....	26
Şekil 4.2. Cinsiyet sonuçları karışıklık matrisi	33



TABLO LİSTESİ

	Sayfa No
Tablo 1.1. Kişi Tanımlamada Kullanılan Biyometrik Özellikler	2
Tablo 2.1. Hata (karışıklık) Matrisi	17
Tablo 4.1. Veri setindeki cinsiyetlerin dağılımı	25
Tablo 4.2. Farklı Transfer Öğrenme Algoritmalarının Doğruluk Oranları.....	27
Tablo 4.3. ResNet50 Özniteliklerinin farklı sınıflandırma yöntemleri ile elde edilen sonuçlar	28
Tablo 4.4. 10-katlı çapraz doğrulama sonuçları	29
Tablo 4.5. Farklı Transfer Öğrenme Algoritmalarının Doğruluk Oranları.....	30
Tablo 4.6. ResNet152 Özniteliklerinin farklı sınıflandırma yöntemleri ile elde edilen sonuçlar	31
Tablo 4.7. 10-katlı çapraz doğrulama sonuçları	32
Tablo 4.8. Farklı Transfer Öğrenme Algoritmalarının Doğruluk Oranları.....	34
Tablo 4.9. ResNet152 Özniteliklerinin farklı sınıflandırma yöntemleri ile elde edilen sonuçlar	35
Tablo 4.10. 10-katlı çapraz doğrulama sonuçları.....	36

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
g_p	: p indisli ses verisi
g_c	: 3x3 matrisin merkez verisi
x	: iki hücre arasındaki fark

Kısaltmalar	Açıklama
YSA	: Yapay Sinir Ağları
DVM	: Destek Vektör Makineleri
k-NN	: K Nearest Neighborhood
LBP	: Local Binary Pattern



ÖZET

YÜKSEK LİSANS TEZİ

FARKLI TRANSFER ÖĞRENME YÖNTEMLERİNİN KARŞILAŞTIRILMASI İLE GÖZ ÇEVRESİ GÖRÜNTÜLERİNDEN KİŞİ TANIMA

Yasr Mahdi HAMA RASHID

**Kırşehir Ahi Evran Üniversitesi
Fen Bilimleri Enstitüsü
İleri Teknolojiler Anabilim Dalı**

Danışman: Doç. Dr. Emrah AYDEMİR

İkinci Danışman: Dr. Öğr. Üyesi Cemal AKTÜRK

Makine öğrenmesi yöntemleri, belirli bir problemin çözümünde bir veri setinin eğitilerek o veri setinden aranılan bir özelliğin veya parametrenin öğrenilmesi, tahmin edilmesi gibi amaçlar için kullanılır. İnsanın geçmiş bilgi ve deneyimlerinden öğrenmeyi sürdürme yeteneğinin bilgisayar sistemlerine aktarılması hedeflenen transfer öğrenme yaklaşımında da esas alınan belirli bir problemin çözümünde elde edilen öğrenmenin yeni bir problem çözümünde kullanılabilirlik üzere aktarılmasıdır. Transfer öğrenmede elde edilen öğrenmenin aktarılabilmesi, geleneksel makine öğrenmesi yöntemlerine göre birtakım avantajlar sağlamaktadır ve bu avantajları transfer öğrenmenin tercih edilmesinde etkili olmaktadır. Bu çalışmada 96 farklı kişiye toplam 1980 göz çevresi görüntüsü toplanmıştır. Toplanan bu veriler kişi, yaş ve cinsiyet açısından sınıflandırılmaya çalışılmıştır. Bunun için Python programı içerisinde yer alan 32 farklı transfer öğrenme algoritması ile öznelik çıkarımı yapılmış ve kişi tahmini için RandomForest algoritması ile sınıflandırılmıştır. En yüksek başarı gösteren ResNet50 algoritması ile 30 farklı sınıflandırma algoritması kullanılmış ve veriler yaş ve cinsiyet açısından da sınıflandırma yapılmıştır. Böylece sırasıyla kişi, yaş ve

cinsiyet sınıflandırılmasında en yüksek başarı oranları olarak %83,52, %96,41 ve 77,56 elde edilmiştir.

Haziran 2022, 60 Sayfa

Anahtar Kelimeler: Göz çevresi görüntüsü, transfer öğrenme, sınıflandırma



ABSTRACT

MASTER THESIS

PERSON RECOGNITION FROM EYE CIRCUMFERENCE IMAGES BY COMPARISON OF DIFFERENT TRANSFER LEARNING ALGORITHMS

Yasr Mahdi HAMA RASHID

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

Supervisor: Assoc. Prof. Dr. Emrah AYDEMİR

Second Supervisor: Assist. Prof. Dr. Cemal AKTÜRK

Machine learning methods are used for purposes such as learning and estimating a feature or parameter sought from that data set by training a data set in solving a particular problem. The transfer learning approach, which is aimed at transferring the ability of people to continue learning from their past knowledge and experiences to computer systems is the transfer of the learning obtained in the solution of a particular problem, so that it can be used in solving a new problem. Transferring the learning obtained in transfer learning provides some advantages over traditional machine learning methods, and these advantages are effective in the preference of transfer learning. In this study, a total of 1980 eye contour images were collected from 96 different people. These collected data were tried to be classified in terms of person, age and gender. For this, feature extraction was performed with 32 different transfer learning algorithms in the Python program and classified with RandomForest algorithm for person estimation. 30 different classification algorithms were used with the most successful ResNet50 algorithm, and the data were also classified in terms of age and gender. Thus, the

highest success rates were obtained as 83.52%, 96.41% and 77.56% in person, age and gender classification, respectively.

June 2022, 60 Pages

Keywords: Eye image, transfer learning, classification.



1. GİRİŞ

Bilgi ve internet teknolojilerinde yaşanan hızlı gelişmeler, teknolojinin kullanım alanlarını da arttırmıştır. Akıllı telefon, tablet, akıllı saat gibi mobil teknolojilerin yaygınlaşması ile kamusal ve özel alanlarda kullanılan elektronik kontrol sistemleri de gün geçtikçe yaygınlaşmıştır. Kablosuz internet bağlantısı sayesinde günümüzde neredeyse tüm binalarda, cadde ve sokaklarda, toplu taşıma araçlarında güvenlik kameraları ve çeşitli algılayıcı sistemleri ile takip ve kontrolün kolaylaşması, bilişim teknolojilerinin sunduğu avantajlardan biridir. Kameralardan kaydedilen görüntülerin ve toplanan dijital verilerin artması, bir takım ihtiyaçları da beraberinde getirmektedir. Görüntü verilerinin artması, bu görüntüleri analiz etmede gereken insan gücünü de gün geçtikçe arttırdığından daha etkili bir kontrol için elektronik sistemlerden daha fazla yararlanma ihtiyacı ortaya çıkmaktadır. Verilerden ihtiyaç duyulması muhtemel olan nesnelerin tespitinin otomatik yapılabilmesi, bu nesnelerin takibini ve kontrolünü oldukça kolaylaştırmaktadır. Örneğin plakadan araç tanıma, biyometrik verilerden kişileri tanıma gibi sistemler görüntülerin analiziyle nesneleri ve kişileri tanımlayarak güvenlik, takip ve kontrolü kolaylaştıran sistemlerdir.

Biyometri canlıların fiziksel, kimyasal ve davranışsal özelliklerini ölçen bir bilimdir ve insanlar özelinde kimlik tanımaya odaklanır [1]. Temelde istatistiksel yöntemlerin tıp ve biyoloji alanında kullanılmasını kapsayan bir alandır. Anne karnındaki bir bebeğin ultrasonografi aracılığıyla ölçümlerinin yapılması, ölçülerden gebelik haftasının veya doğum tarihinin hesaplanması gibi örnekler biyometri alanına girmektedir.

Biyometri, bilgisayar bilimleri alanında fiziksel ve karakteristik özelliklerinden kişileri tanımlamada sıklıkla kullanılmaktadır. Kişileri tanımda kullanılan biyometrik özellikler Tablo 1’de gösterilmektedir [2-5]. Tablo 1’den görülebileceği üzere biyometrik özellikler genel olarak kişilerin kendi anatomilerinden kaynaklanan fiziksel özelliklerinden ve davranışsal özelliklerinden oluşmaktadır. Ses, her ne kadar fiziksel bir özellik olarak sınıflandırılrsa da hastalık durumuna bağlı olarak değişebileceği veya bireyler tarafından özellikle farklılaştırılabilir olduğundan dolayı hem fiziksel hem de davranışsal bir biyometrik özellik olarak düşünülebilir.

Tablo 1.1. Kiři Tanımlamada Kullanılan Biyometrik Özellikler

Fiziksel Biyometrik Özellikler	
Özellik Adı	Açıklama
Parmak İzi	Parmakların deseni ve gözeneklerinin yapısı kullanılır.
İris	Gözün iris bölgesinden dokuya dayalı olarak iris deseni tanımlanarak kullanılır.
Retina	Göz bebeğinin arkasındaki damar tabaka olan retinanın tanımlanmasıdır.
Yüz Yapısı	Göz, burun ve ağız gibi organların ölçümleri ve birbirleriyle uzaklıklarının analiz edilmesiyle tanımlanır.
El Geometrisi	Avuç içinin ve parmakların eklem yerleri ve birleşme yerleri arasındaki uzaklıklar gibi fiziksel karakteristikleri kullanılır.
El Damar Yapısı	Parmak içlerinde ve el yüzeyindeki damaların yapısı kullanılır.
Kulak Biçimi	Kulak yapısındaki ölçümlerle tanımlanır.
Koku	Kişinin vücut kokusunun kimyasal bileşimleri kullanılır.
DNA	Kişinin genetiğini oluşturan proteinlerin dizilimi olan DNA kullanılır.
Ses	Sesin tonu, rengi kullanılır.
Davranışsal Biyometrik Özellikler	
Özellik Adı	Açıklama
İmza	Kalem tutma, yazma özellikleri ve hız ile tanımlanır.
El Yazısı	Harflerin oluşturulma sırası ve oluşturulma biçimi gibi özellikler kullanılır.
Klavye Tuşlarına Vuruş Tarzı	Klavye tuşlarına vuruşların ritmik özellikleri kullanılır.
Yürüyüş (Ayak İzi) Biçimi	Ayaktaki şekil, parmak, uzunluk gibi farklılıklar ile yürüyüşte meydana çıkan izlerdeki farklılıklar tanımlanabilir.

Biyometrik tanıma sistemleri, kişilerin daha önceden kayıt altına alınmış biyometrik özelliklerini, kişinin mevcut durumundan veya davranışından tarama ve analiz yoluyla karşılaştırarak kişileri tanımlamaya yarayan sistemlerdir [5] . Biyometrik tanıma sistemlerinin doğru ve güvenilir çalışması için kişilerin biyometrik özelliklerinin ölçümünde ve

kaydedilmesinde hata olmamalıdır. Bunu güvence altına almak için kayıt işlemleri birden çok tekrar ile ölçümler yapılarak kayıt alınmalıdır[5].

Kimlik tanıma ve doğrulamada kullanılan geleneksel yöntemler olan manyetik kartlar, anahtarlar veya şifrelerine kıyasla biyometrik güvenlik sistemlerinin sunduğu çok önemli avantajlar bulunmaktadır. Bu avantajların en başında bir biyometrik tanıma sisteminin kişiden kişiye benzersiz olan özellikleri temel aldığından; hırsızlık, gizlilik ihlali veya geleneksel doğrulama araçlarının kaybedilmesi gibi nedenlerle güvenlik tehdidiyle karşı karşıya kalmayacak olması gelmektedir.

Genellikle biyometrik tanıma sistemlerinin kullanımı ve yönetilmesi kolaydır ve bu kolaylığı yönüyle sistemin tedarikçilerine ve kullanıcılarına verimlilik sunar. Böyle bir sistemi kullanırken ana doğrulama aracı kişinin kendisi olduğu için kullanıcıların herhangi bir şifreyi veya pin kodunu hatırlaması veya saklaması gerekmemektedir. Kullanıcıların hesapları kapalı devre bir sistem içerisinde olduğu için dış sistemlerle genelde paylaşılmaz. Eğer daha gelişmiş veya kompleks bir güvenlik sisteminin kullanılmasının gerekli olduğu durumlarda yüz tanıma, göz tanıma, parmak izi tanıma veya ses tanıma gibi birden fazla biyometrik özelliğin kullanılabilme imkânı bulunmaktadır.

Buna karşın biyometrik tanıma sistemlerinin her kullanıcı için kullanıma uygun olmadığı durumlar da söz konusu olabilir. Yüz, göz veya parmak gibi organlarında hasar veya engel bulunan kullanıcıların bu sistemlere tanımlanması veya engelli bireylerin bu sistemleri kullanması problem teşkil edebilir. Bir biyometrik tanıma sisteminin verimli olarak kullanılabilmesi için muhattap tüm kullanıcıların sisteme tanımlanabilir olması ve sistemi kullanabilir olması gerekmektedir. Buna ek olarak biyometrik tanıma sistemlerinin ilk yatırım maliyetleri de kurum ve kuruluşlar için yüksek karşılanabilir. Özellikle birden fazla doğrulama yönteminin kullanıldığı ve karmaşık yazılım sistemleriyle entegre olan sistemlerde sahip olma maliyetlerin yüksek olacağı kaçınılmazdır [6].


Ancak biyometrik tanıma sistemlerinin dezavantajları bunlarla da sınırlı değildir. Güvenlik boyutu itibariyle, parmak izi tanıma sistemlerinde kişilerin parmak izleri kalıplar aracılığıyla taklit edilerek sistem kandırılabilir. İris tanıma sistemleri için de aynı durum söz konusu olabilir. Kişilerin iris deseninin lenslere basılarak bu lensleri yüksek çözünürlüklü iris görüntüsünün üzerine yerleştirip sistemin aşılma olasılığı muhtemeldir [2]. Kişilerin gözlük kullanması veya sabit bir okuyucuya bakmaması da retina tarama sistemlerinin dezavantajı

olarak görülebilir [5]. Yine el, yüz ve parmaklarda oluşabilecek hasar, deformasyon ve yaralanmalar bu organların kullanıldığı tanıma sistemlerinde doğrulamanın yapılamamasına sebebiyet verebilir. Bu tür dezavantajlar biyometrik tanıma sistemlerinin performanslarını, güvenilirliğini ve dolayısıyla kullanılabilirliğini doğrudan etkilemektedir.

Biyometrik özelliklerin kullanılarak kişilerin tespit edilmesi, tanınması ve görüntü içerisindeki yüzlerin tespiti kimlik tanımlama ve kimlik doğrulama açısından oldukça önemlidir. Özellikle görüntülerin analizi ile biyometrik tanımlama ve doğrulama konusundaki çalışmalar son 10 yılda giderek daha çok ilgi çekmeye başlamıştır. Biyometrik sistemler konusunda araştırmacılar her geçen gün biyometrik sistemlerin performanslarını ve kullanılabilirliğini artıran çalışmalara odaklanmaktadır ve bu alandaki çalışmaların sayısında artışlar görülmektedir. Bu artan ilgi araştırmacıları daha uzak mesafelerden tanımlama yapmaya yönlendirmekte ve bu alandaki çalışmaların artması ile kişi tanıma sistemleri hem daha yüksek verime sahip olmakta hem de gizli gözetimin yanı sıra biyometrik tanımlama sistemlerinin kullanılabilirliği de artmaktadır [7].

1.1. Gözün Anatomik Yapısı

Gözler, tüm omurgalılarda kemik veya kıkırdaktan oluşan bir göz çukurunda bulunan organlardır. Bulunduğu canlıların çoğunda gözler yağ, bağ ve kas sisteminden oluşan bir yapıdadır ve belirli bir hareket kabiliyetine sahiptir. Canlıların genelde dış ortama açık tek organı olarak korunma ihtiyacı bulunan göz, kafatası ve göz kapağı ile de desteklenmektedir. [8]. İnsan gözünün anatomik yapısı Şekil 1.1'de gösterilmektedir [9].



Şekil 1.1. Gözün anatomik yapısı [9]

İnsanların göz küresi, orbita adı verilen koruyucu bir kemik çukuru içerisinde yer alır ve dıştan fibröz bir bağ dokusu ile kaplıdır ve gözün ön kısmında gözbebeği ile irisi kaplayan kornea tabakası bulunur. Alt ve üst kısmından kaslarla bağlı olan göz, bu kaslar sayesinde aşağı-yukarı, sağa-sola hareket etme kabiliyetine sahip olur. Gözün önemli anatomik kısımları aşağıda açıklanmıştır [8, 10]:

- **Kornea (Cornea):** İrisin önünde bulunan şeffaf tabakadır. Göze gelen ışınları alarak retinaya iletir.
- **İris:** Göze giren ışık miktarını düzenlemeye yardımcı olan, göze rengini veren kısımdır. Göze gelen ışık miktarı arttığında gözbebeğini küçültür, ışık miktarı az olduğunda ise daha iyi bir görme için göz bebeğini genişletir.
- **Lens:** Mercek görevi görerek göze gelen ışınları retinaya odaklar. Lens şeffaftır ve gerek görüldüğünde değiştirilebilir. Çünkü yaşlandıkça deforme olabilmektedir.
- **Optik sinir (Optic Nerve):** Retinadan beyne görsel uyarıları taşıyan bir milyondan fazla sinir lifinden oluşan bir demettir.
- **Pupilla (Göz Bebeği):** İrisin ortasında bulunur ve ışık miktarına göre büyüüp küçülme özelliğine sahiptir.

- **Retina:** Gözün arkasında bulunan ve ışığın algılanmasına olanak sağlayan sinirlerden oluşan tabakadır. Retina ışığı algıladıktan sonra optik sinir yoluyla beyne gönderilen görsel uyarıları oluşturmaktadır.
- **Sklera (Sclera):** Gözün irisi çevreleyen koruyucu sert ve beyaz bir tabakadır.

İnsan yüzüne bakıldığında en çok dikkat çeken yer arasında gözlerin olduğu söylenebilir. Göz ve çevresi insanların farklı duygularını ifade etmelerinde farklı şekillere ve hareketlere sahip olurlar. Bu sayede göz ve çevresi insanların bilişsel süreçleri, duygu ve düşünceleri hakkında fikir edinmeye olanak sağlamaktadır. Bu durum otomatik sınıflandırma çalışmalarında göz ve çevresinin kullanılabilirliğine imkan sunmaktadır [11]. Göz tanıma ile ilgili uygulamalarda özellikle iris tanımlama, göz bebeği ve skleranın iç ve dış sınırlarının tespiti, göz kapağının alt-üst sınırlarının tespiti, kirpiklerin ve korneanın tespiti gibi aşamalar bulunmaktadır. Bu aşamaların bir kısmı daha çok ilgi odağı olurken bir kısmı göz ardı edilebilmektedir [12].

İris tanıma veya irisin taranması, bir kişinin yakın mesafeden irisinin yüksek karşıtlı kızılötesi fotoğrafını çekerek iris desenini oluşturmayı ve bu deseni ikili veriye dönüştürme sürecini kapsamaktadır. İris tanımının amacı benzersiz ve karmaşık bir desene sahip olan irisin bu deseninin matematiksel modelini çıkararak kişilerin biyometrik sistemler tarafından tanınmasında ve kimlik doğrulamasında kullanmaktır. Kişilerin parmak izlerini değiştirmesi, gizlemesi veya bozması kendi irisine müdahale etmesinden daha kolay olduğundan iris tanıma sistemlerinin parmak izi sistemlerinden hem daha hızlı hem daha güvenli olduğu ifade edilmektedir [12]. Buna karşın iris taraması yaparken bazı dezavantajlar da bulunmaktadır. İris tanımada normal kameraların kullanımında gözün ışığı yansıtmasından dolayı tarama doğruluğu azalmaktadır. Bunun için kızılötesi ışık kaynağını kullanan kameralar kullanılmalıdır. Ayrıca tarama işlemi için kameraya 15-20 cm gibi bir yakınlık olması gerekmektedir. Kayıt ve doğrulama için bu yakınlık kullanıcılarda rahatsızlığa neden olabilmektedir.

Bu tez çalışmasında, öncelikle kişilerin göz görüntülerinden yeni bir veri seti elde edilmiştir. Oluşturulan veri seti üzerinde yapay zeka teknikleri kullanılarak geliştirilen bir model ile göz görüntülerinin sınıflandırılması sağlanmıştır. Böylelikle göz görüntülerinin sınıflandırılmasıyla kişilerin kimlik tespiti gerçekleştirilmiştir.

1.2. Amaç ve Önem

Yapay zeka, bilgisayar bilimlerinde bir çalışma alanı olarak insan gibi düşünen veya insan gibi davranan sistemler geliştirmeyi esas almaktadır. İnsana has hareket kabiliyetleri ile nesnelere insan zekası tarafından tanımlanması, anlaşılması yapay zekanın taklit etmeye çalıştığı özellikler arasında yer almaktadır. Benzer şekilde konuşan bir kişinin sesinden ne demek istediğini anlamak ve ona karşı bir yanıt oluşturmak, herhangi bir problem karşısında nasıl bir adım atılacağı konusunda karar vermek gibi fonksiyonlar yapay zeka sistemlerinin ilgi odağında bulunmaktadır.

Yapay zekanın bir alt grubu olan makine öğrenmesi yöntemleri, belirli bir büyüklükteki veri setleri üzerinde doğrulama ve tahmin etme işlemlerini yapmada kullanılmaktadır. Makine öğrenmesi, insanın mevcut bilgilerini kullanarak yeni bir öğrenme sürecine girmesini ve sürekli öğrenmeyi devam ettirmesi özelliklerine karşılık bilgisayar sistemlerinin veriye dayalı olarak bu öğrenme biçimine uyarlanmasıdır. Bilgisayar sistemleri ile bu teknolojinin sahip olduğu veri işleme kapasitesi sayesinde makine öğrenmesi yöntemleri kullanılarak günlük hayatta insanların baş etmekte zorlanacağı hatta çözemeyeceği problemlerin çözümünde oldukça yararlı olmaktadır.

Bilgisayar ile görmenin bir dalı olan yüz tanıma, insan yüzünün göz, burun, ağız gibi organlarının ölçümleri ve birbiriyle mesafesinin matematiksel modellenmesi temeline dayanmaktadır. Yüz tanıma sistemleri kimlik doğrulamada ve kişi tespitinde kamu ve özel sektörde sıklıkla kullanılan bir biyometrik tanı sistemi olmuştur. Ancak son yıllarda tüm dünyayı etkisi altına alan ve maske kullanımını zorunlu kılan korona virüs gibi salgınlar, yüz tanıma sistemlerinin maskeden kaynaklı olarak başarısını oldukça düşürmüştür. Çünkü maske kullanımından dolayı yüzün ağız, burun, çene gibi diğer önemli bölgeleri tanımlanamadığından dolayı kişilerin yüz tanıma sistemleriyle tespiti zorlaşmıştır. Ayrıca insan yüzünün yaşlanması, deformasyonu, küçük resim boyutu, kötü görüntü kalitesi, farklı yüz açıları gibi nedenlerle yüzün tanımlanamaması bu sistemlerin diğer önemli sorunlarını oluşturmaktadır. Yüzün tamamını ilgilendiren bu sorunlara karşın gözler daha küçük organlar olup biyometrik tanıma yönünden gözlerin değiştirilmesi veya göze herhangi bir müdahalede bulunulması oldukça zordur. Bu gerekçelerden yola çıkılarak bu çalışmada göz görüntülerinden biyometrik veriler elde etmek amaçlanmıştır. Bir başka ifade ile göz görüntülerindeki biyometrik farklılıkların makine öğrenmesi algoritmalarıyla tespit edilerek kişilerin göz görüntülerine göre sınıflandırılması amaçlanmıştır. Yapılan çalışmanın önemi,

veri toplama ve biyometrik tanımda hemen herkeste bulunan kameraların kullanılmasıyla ekonomik verimliliğe sahip biyometrik sistemlerin geliştirilebildiğini göstermektedir. Çünkü göze dayalı tanıma sistemleri olan iris ve retina tanıma sistemleri yüksek maliyetli ve düşük kullanılabilirliğe sahip olan cihazlara ihtiyaç duyulmasını gerektirmektedir. Bu sistemler için kızılötesi ışığı olmayan donanımlar ile veri elde etmek de mümkün değildir. Oysa yapılan çalışmada akıllı telefon kamerası kullanılarak göz görüntüleri elde edilecektir. Elde edilen görüntülerden oluşan veri setinin probleme özgü makine öğrenmesi yöntemleri kullanılarak göz görüntüleri sınıflandırılacaktır. Böylelikle kişisel bir akıllı telefon bile biyometrik göz tanıma sistemine uyarlanabilir olacaktır.

1.3. Yapılan Çalışmalar

Cerme ve diğ. [13] tarafından yapılan çalışmada, farklı göz modellerini kullanarak bu gözlere ait irislerin 3 boyutlu yapısının iris tanıma üzerindeki etkisini araştırmıştır. Sonuç olarak, önden ve açılı olmayan iris görüntüleri arasındaki açı arttıkça irisler arasındaki mesafenin de arttığı gözlemlenmiştir. Bu nedenle, ayrık iris tanımda doğru sonuçlar elde etmek için üç boyutlu iris dokusunun dikkate alınmasının yararlı olacağı araştırmacılar tarafından vurgulanmıştır.

Zhang ve diğ. [14] yaptıkları çalışmada sağlam iris özelliği eşleştirmesi için yeni bir iris tanıma yöntemi önermiştir. Önerilen yöntemde ilk olarak, iris görüntülerinin sınıf içi varyasyonlarına karşı dayanıklı olan bölgesel iris özelliklerini temsil etmek için yoğun DAISY tanımlayıcıları çıkarılır. Ardından özellik haritasında bir dizi iris kilit noktası yerleştirilir. Son olarak, iris görüntülerinin karşılık gelen anahtar noktalarına uyması için deformasyona toleranslı eşleştirme stratejisi önerilmiştir. İki iris görüntü veri tabanındaki deneysel sonuçlar, Bu yöntemin son teknoloji iris tanıma yöntemlerinden daha iyi olduğu araştırmacılar tarafından gösterilmektedir. Elde edilen sonuçlar, DB1 veri setinde 0.21% EER ve Lamp veri setinde 0.59 EER değerlerine ulaşmıştır.

Azimi ve diğ. [15] tarafından yapılan çalışmada ise kullanıcıların cinsiyet ve sağlık durumlarına göre irisler için iris tanıma sisteminin bir performans analizini sunar. Araştırmacılar sağlık durumu olarak diyabetten etkilenen ve sağlıklı kullanıcıları tanımlamıştır. Araştırmada kullanılan veritabanı, 162 sağlıklı irisden (% 62 kadın kullanıcı, %38 erkek kullanıcı) 546 resim ve açıkça görülebilen iris desenine sahip 181 diyabetik gözden elde edilen toplam 772 iris görüntüsünden (%80 kadın kullanıcı, %20 erkek kullanıcı)

oluşmaktadır. Adaptif ağırlıklı Hough elipsopolar iris segmentasyonu için dönüştürme tekniği kullanılmış ve ardından üç popüler iris kodlama algoritması uygulanmıştır. “Bhattacharyya” mesafesi erkeklerin ve kadınların diyabetik ve sağlıklı süsenlerinin karşılaştırılmasında kullanılmıştır. Yapılan çalışmanın sonucunda iris tanıma sisteminin performansı üzerinde erkeklerdeki diyabetik etkilerin kadın kullanıcılar için daha yoğun olduğu araştırmacılar tarafından gözlemlenmiştir.

Wang ve diğ. [16] tarafından IrisParseNet adında yüksek verimli derin öğrenme tabanlı bir iris segmentasyonu yöntemi önerilmiştir. Önerilen yöntemde önceki birçok CNN tabanlı iris segmentasyon yönteminden farklı olarak popüler semantik segmentasyon çerçevelerini izleyerek yalnızca doğru iris maskelerini tahmin etmeye odaklanan ve yeni bir yaklaşım önerilmiştir. Önerilen yaklaşımı eğitmek ve değerlendirmek için araştırmacılar üç temsili ve zorlu iris veri tabanını manuel olarak etiketlemektedir. Bu veritabanları, “CASIA.v4-distance”, “UBIRIS.v2” ve “MICHE-I.” veritabanlarıdır. Yapılan çalışmada bu veritabanlarından sırasıyla %94,25, %91,78, ve %93,05 başarı oranları elde edilmiştir.

Bakshi ve diğ. [17] tarafından iris tanıma sisteminin arama doğruluğunu arttıran yeni bir model önerilmiştir. Önerilen modelde kullanılan homojen olmayan K-d ağaç yapısı, iris kodunu depolar ve eşleştirir. Önerilen model, IITD ve CASIA veri setleriyle test edilmiştir. Bu veri setlerinde sırasıyla %99,34 ve %98,5 doğruluk elde edilmiştir.

Gangwar ve diğ. [18] tarafından iris gösterimi için DeepIrisNet olarak adlandırılan derin öğrenmeye dayalı bir yöntem sunulmuştur. Sunulan yaklaşım, son zamanlardaki başarılı CNN'lerden alınan çeşitli yaklaşımları ve derin öğrenme mimarisini içermektedir. Araştırmacılar doğrulamada iki farklı veri seti olarak “ND-iris-0405” ve “ND-CrossSensor-Iris-2013” veri setlerini kullanmıştır.

Dong ve diğ. [19] tarafından iris tanıma sistemlerinin verimini artırmak amacıyla uyarlanabilir bir iris eşleştirme yöntemi geliştirilmiştir. Yöntemin ana fikri, iris eşleştirme modülünün karar eşiğini, giriş iris görüntüsünün kalite ölçüsüne göre dinamik olarak ayarlamaktır. Gerçek sistemdeki deney sonuçları önerilen yöntemin etkinliğini göstermektedir. Yapılan deneysel çalışma ile CASIA 1.0 veri setinde 95.73 doğruluk elde edilmiştir.

Devi ve diğ. [20] tarafından ikizlere odaklanarak iris segmentasyonu ve iris tanıma için otomatik bir yaklaşım gösterilmiştir. Araştırmacılar teknik olarak irisin lokalize

edilmesini ve bölümlenmesini, ardından iris normalizasyonunu ve ayırt edici özelliklerin elde edilmesi gerektiğini ifade etmiştir. Son olarak, ikizlerde bire bir ve bire çok tanınma sağlamak için iris şablonları eşleştirilir. Ayrıca, çeşitli şablon boyutlarının doğruluk ve bellek gereksinimi üzerindeki etkisi bu çalışmada incelenmiştir.

Sharkas ve diğ. [21] tarafından her iki gözün kullanıldığı bir iris tanıma sistemi için yeni bir yaklaşım geliştirilmiştir. Yapılan çalışmada CASIA iris veritabanının üçüncü versiyonundaki üç kişinin sağ ve sol gözlerine ait görüntüler kullanılmıştır. Öncelikle tüm gözden iris görüntüsü çıkarılır, iris normalleştirilir ve güçlendirilir. Geliştirilmiş iris tabakasına tek seviyeli ayırık dalgacık dönüşümü uygulanır. Yaklaşım katsayılarının 8×8 veya 4×4 bloklarının ortalaması değerlendirilir ve iris kodu üretilir. Sağ göz kodu kullanılarak eğitilen ve sol göz kodu kullanılarak test edilen bir sistem ile %75'lik bir maksimum tanıma oranına ulaşılmıştır. Daha sonra eğitim veri seti olarak sağ gözden ve diğer yarısı sol gözden gelen verilerin yarısı kullanılıp kalan yarısı test için kullanıldığında 1647 uzunluğundaki bir vektör elde edilmiş ve %98,3 tanıma oranına ulaşılmıştır. Araştırmacılar yaklaşım katsayılarının 8×8 bloklarının ortalaması daha sonra aynı şekilde kullanarak %100'e ulaşan tanıma oranını iyileştirirken kod boyutunda da azalma elde etmiştir. Aynı işlem, 4×4 blokların ortalamasının hesaplandığı ve çok daha küçük boyutlu bir özellik vektörü oluşturmak için kullanıldığı 2. düzey ayırık dalgacık dönüşümünün yaklaştırılması için de yapılmıştır. Önerilen tekniğin üstünlüğünü doğrulayan bu durumda da tanıma oranı %100'e ulaşmıştır.

Chun ve diğ. [22] tarafından irisi çevreleyen hem lokalize hem de global göz bölgelerindeki istatistiksel gri seviye bağımlılıklarından yararlanan yeni bir anti-spoofing yaklaşımının geliştirilmesi sunulmuştur. Anonim olan sahte iris görüntü veritabanında deneysel sonuçlar bu çalışmada sunulmuştur. Yapılan çalışmada 1200 görüntüden oluşan veritabanında %99,75'lik doğru sınıflandırma oranı elde edilmiştir.

Mayank ve diğ. [23] tarafından kırmızı, yeşil ve mavi olmak üzere üç spektral kanalla karakterize edilen renkli iris görüntülerinin kullanıldığı çalışmada, tanıma doğruluğunu iyileştirmek için kalite tabanlı bir füzyon şeması önerilmiştir. Önerilen yöntemde, bir Yedekli Ayırık Dalgacık Dönüşümü (RDWT) kullanılarak görüntü düzeyinde birleştirilen iki renkli iris görüntüsünün iki kanalını seçmek için kalite puanları kullanılmıştır. Kaynaştırılan görüntü daha sonra tanıma doğruluğunu artırmak için kalan kanalla birlikte puan düzeyinde bir füzyon çerçevesinde kullanılmaktadır. Heterojen renkli iris veri tabanındaki deneysel sonuçlar ile

teknikinin etkinliğini gösterilmiştir. Önerilen yöntem, renkli iris görüntülerinin NIR muadilleri ile bağlantılı olarak kullanılmasından potansiyel olarak fayda sağlayabilir. Yapılan çalışmada WVU multispektral iris veritabanı kullanılarak 99% doğruluk oranı elde edilmiştir.

Zhang ve diğ. [24] tarafından kontrolsüz durumlarda düşük kaliteli görüntüler için hiyerarşik bir füzyon şeması önerilmiştir. Eğitim aşamasında, piksel seviyesinde yüzden irise istatistiksel bir eşleme oluşturmak için kanonik ilgileşim analizi (CCA) bu çalışmada kullanılmıştır. Bu çalışmada oluşturulan veri tabanı, 82 kişiden alınan 1640 iris görüntüsünden oluşmaktadır ve test sonuçlarının 100%'lük doğruluk verdiği iddia edilmiştir.

Jalilian ve diğ. [25] tarafından farklı bakış açılarının CNN tabanlı açı dışı iris segmentasyonları üzerindeki etkisi ve bunların tanıma performansı araştırılarak, açı dışı bozulmaların neden olduğu bazı segmentasyon bozulmalarını telafi etmek için bir iyileştirme şeması sunulmuştur. Ayrıca, açılı görüntüleri önden görünüme yeniden yansıtma için bir açı dışı parametreleme algoritması önerilmiştir. Ayrıca araştırmacılar deneklerin 4400 sol göz iris görüntüsünden oluşan bir alt veri seti daha oluşturarak bu veri setiyle %93.32 doğruluk elde etmiştir.

Sun ve diğ. [26] tarafından doku analizine dayalı iris görüntü sınıflandırması için genel bir çerçeve olarak iris görüntülerinin doku temellerini kodlamak için Hiyerarşik Görsel Kod Kitabı (HVC) adı verilen yeni bir doku deseni temsil yöntemi önerilmiştir. Önerilen HVC yöntemi, mevcut iki Kelime Çantası modelinin, yani Kelime Bilgisi Ağacı (VT) ve Lokalite-kısıtlı Doğrusal Kodlama (LLC) yönteminin entegrasyonundan oluşmaktadır. HVC, genelden inceye bir görsel kodlama stratejisi benimser ve iris dokusunun doğru ve seyrek gösterimi için hem VT hem de LLC'nin avantajlarından yararlanır. Kapsamlı deneysel sonuçlar, önerilen iris görüntü sınıflandırma yönteminin iris canlılığı tespiti, ırk sınıflandırması ve kabadan inceye iris tanımlaması için son teknoloji performansa ulaştığını göstermektedir. Yapılan bu çalışmada ND-Contact veri seti kullanarak elde edilen doğruluk oranı %98,93'tür.

Frigerio ve diğ. [27] tarafından açılı olmayan iris görüntüsünü düzeltmek için yeni bir yöntem önerilmiştir. Dış şeffaf katmanların göz morfolojisi ve yansıtma özelliklerini hesaba katarak elde edilen görüntüde mevcut olan bozulma etkisi değerlendirilmektedir. Çalışmada WVU off-angle iris veritabanı kullanılmıştır ve 0.460 hata oranı elde edilmiştir.

Gale ve diğ. [28] tarafından bir iris tanıma sisteminin performansını iyileştirmek amacıyla irisin belirli bölümlerindeki özellikleri çıkarmak için Haar dönüşümü, PCA, Blok toplam algoritması kullanılmıştır. Araştırmacılar iris doğrulaması için melez bir algoritma kullanarak görüntü dönüştürme performansının karşılaştırmalı bir çalışmasını sunmuştur. Deneysel sonuçlar, bu tekniğin CASIA VI iris veri tabanında iyi performans ürettiğini göstermektedir ve önerilen çalışma ile 98% doğruluk oranı elde edilmiştir.

Dillak ve diğ. [29] tarafından Elman Tekrarlayan Sinir Ağı / Levenberg-Marquardt algoritmasına dayalı doğruluk elde etmek için bir yöntem önerilmiştir. Araştırmacılar, CASIA-Iris-Syn v4 kullanılarak doğruluk oranının %91'e ulaşabileceğini ve iris tanıma talebini karşılayabilen CASIA-Iris-Syn v1 veritabanını kullanılarak %94,22'lik doğruluk oranına ulaşabileceğini göstermiştir.

Popplewell ve diğ. [30] tarafından Dairesel Hough Dönüşümü (CHT) ve değiştirilmiş Yerel İkili Model (mLBP) özellik çıkarma tekniğini kullanan multispektral bir iris tanıma şeması sunulmuştur. Önerilen şemanın tanımlama ve doğrulama performansı 3120 görüntüden oluşan çok bantlı bir iris veri kümesi kullanılarak doğrulanmış ve 55% doğruluk oranı elde edilmiştir.

Ng ve diğ. [31] tarafından insan irisinin modelini analiz etmek için temel ve hızlı bir Haar dalgacık ayrıştırma yöntemi kullanan bir iris tanıma sistemi önerilmiştir. Bu sistem, CASIA iris veritabanının ile test edilmiş ve %98,45'lik bir doğru tanıma oranı elde edilmiştir.

Danlami ve diğ. [32] tarafından en çok kullanılan filtreler ile Legendre dalgacık filtrelerinin kullanımı önerilmiştir. Bunları üç farklı veri kümesine de test etmişlerdir. Bu veri setleri sırasıyla, CASIA, UBIRIS ve MMU veri tabanlarıdır. Sonuç olarak Legendre dalgacık filtresinin, UBIRIS veri tabanına uygulandığında standart yöntemlere göre %5,4'e varan performans artışı sağladığı gözlemlenmiştir.

2. MATERYAL VE YÖNTEM

2.1. Verilerin Toplanması

Yaşları 3-64 arasında değişen toplam 96 farklı kişiden göz çevresine ait fotoğraflar toplanmıştır. Öncesinde kişilere çalışma hakkında kısa bir bilgilendirme yapılarak verilerin nasıl kullanılacağı ve neler yapılacağı anlatılmıştır. Fotoğraf çekimleri sırasında kendilerini tanımlayacak hiçbir durumun oluşmayacağı açıkça ifade edilmiştir. Ardından her kişinin sağ göz çevresinin en az 10 tane olacak şekilde görüntüsü çekilmiştir. Ayrıca sol göz çevresine de ait en az 10 tane fotoğraf çekilmiştir. Bu fotoğraflar ile birlikte kişilere ait yaş ve cinsiyet bilgisinden başka hiçbir veri kayıt altına alınmamıştır. Aşağıdaki farklı cinsiyette iki kişiye ait görüntüler verilmiştir.



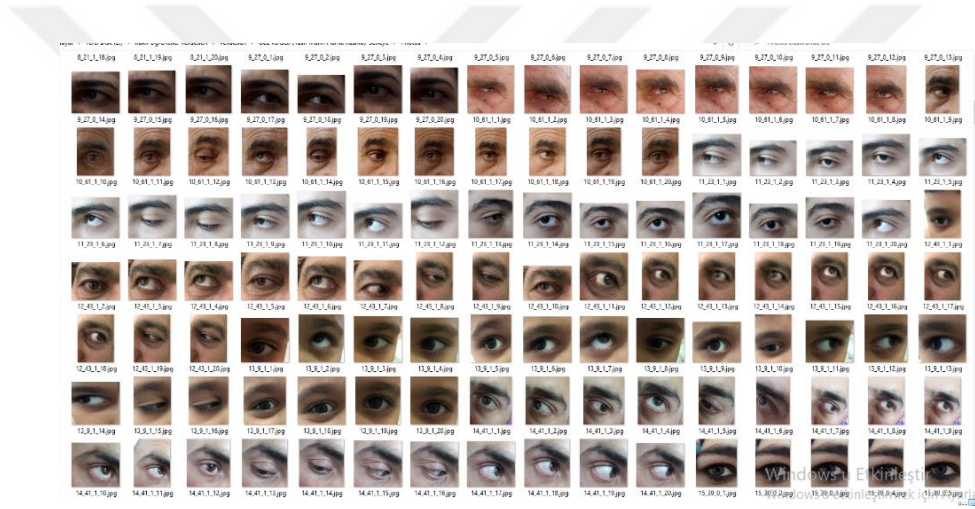
Şekil 2.1. Örnek göz çevresi görüntüleri

Yukarıdaki şekilde görüldüğü şekilde toplam 1980 adet görüntü elde edilmiştir. Bazı kişilerden 10'ar taneden fazla görüntü elde edilmiştir. Bu nedenle sayılarda farklılık vardır. Her bir fotoğrafın aynı kareyi oluşturmaması için farklı açılardan ve farklı ışık alacak şekilde oluşmasına özen gösterilmiştir. Böylece tümü birbirinin aynı olmayan fotoğraflar toplanmıştır. Her bir fotoğrafın bir başka fotoğraf ile karışmaması için kişiyi, yaşını, cinsiyetini ve çekilen fotoğraf numarasını ifade edecek şekilde bir isimlendirme kuralı geliştirilmiştir. Her bir ifade arasına alt çizgi (“_”) karakteri eklenmiştir. İsimlendirme kuralında kullanılan her bir ifade sıralı olarak aşağıda verilmiştir.

- Kişi ID: Fotoğraf çekimi yapılan her bir kişi için tekil olan bir kod değeridir. Bu değer 1-100 arasında değişmektedir.

- Yaş: Kişinin kaç yaşında olduğunu ifade etmek için doğrudan yaşı sayı olarak yazılmıştır. Bu değer 3-64 arasında değişiklik göstermektedir.
- Cinsiyet ID: Fotoğrafi çekilen kişi erkek ise 1 değeri ile kadın ise 0 değeri ifade edilmiştir.
- Fotoğraf ID: Her kişiye ait birden fazla fotoğraf çekimi yapılmış olması nedeniyle her fotoğraf 1-10 arasında sıralı bir şekilde numaralandırılmıştır.

Burada ifade edilen dosya isimlendirme kuralı ile dosya adları ile tüm detaylar görülebilir olmuştur. Böylece tek klasör içerisinde toplanan görüntüler için analizler kolaylaşmıştır. Aşağıda verilen şekilde bu klasör içerisindeki fotoğrafların örnek bir görüntüsü verilmiştir.



Şekil 2.2. Göz çevresi görüntülerine toplu bir bakış

Çalışmada kullanılan veriseti KAGGLE adlı bir veriseti deposunda paylaşılmıştır. <https://www.kaggle.com/datasets/emrahaydemr/photos-of-eyes> adresinden herkesin kullanımına açık olarak indirilebilir. Böylece bu verilerin kullanımı ile yeni araştırmaların yapılmasına imkan tanınmış olacaktır.

2.2. Verilerin Analizi

Python 3.x programı ile tüm veriler analiz edilmiştir. Öncelikle basit istatistiksel analizler yapılmıştır. Bu analizler sonucu verilerin herhangi bir yaş ya da cinsiyet üzerinde yığılma olup olmadığı kontrol edilmiştir. Herhangi bir problemlili dağılıma sahip olmayan bu verilerin analizinde Windows işletim sistemine sahip 40GB RAM ve Intel(R) Core(TM) i5-1035G1 CPU, 3.70GHz işlemcili bir bilgisayar kullanılmıştır. Her bir görüntünün

özniteliklerinin çıkarılmasında yine Python için yazılmış olan keras adlı kütüphanedeki transfer öğrenme algoritmaları kullanılmıştır. 32 farklı algoritma ile her görüntünün özneliği çıkarılmıştır. Böylece en iyi öznitelik çıkarım algoritmasının bulunması amaçlanmıştır. Bu işlem sonrası ise 30 farklı sınıflandırma algoritması ile veriler kişi, yaş ve cinsiyete göre sınıflandırılmıştır. Kullanılan sınıflandırma algoritmaları aşağıda listelenmiştir.

- discriminant_analysis
 - ◆ LinearDiscriminantAnalysis
 - ◆ QuadraticDiscriminantAnalysis
- ensemble
 - ◆ AdaBoost
 - ◆ Bagging
 - ◆ extraTrees
 - ◆ GradientBoosting
 - ◆ HistGradientBoostingClassifier
 - ◆ randomForest
 - ◆ Voting
- linear_model
 - ◆ LogisticRegression
 - ◆ LogisticRegressionCV
 - ◆ PassiveAggressiveClassifier
 - ◆ Perceptron
 - ◆ RidgeClassifier
 - ◆ RidgeClassifierCV

- ◆ SGDClassifier
- naiveBayes
 - ◆ bernoulliNB
 - ◆ CategoricalNB
 - ◆ complementNB
 - ◆ gaussianNB
 - ◆ multinomialNB
- neighbors
 - ◆ KNN
 - ◆ NearestCentroid
 - ◆ RadiusNeighborsClassifier
- neural_network
 - ◆ MultiLayerPerceptron
- svm
 - ◆ LinearSVC
 - ◆ NuSVC
 - ◆ SVM
 - ◆ DecisionTree
 - ◆ ExtraTreeClassifier

2.3. Eğitim ve Test Verilerinin Ayrıştırılması

Bir makine öğrenmesi modeline ait performansı ölçmek için güvenilir bir yol olarak; modeli mevcut verilerle eğitmek ve yeni ya da farklı verilerle sınıflandırma performansını

değerlendirmek kullanılır. Yaygın olarak kullanılan yaklaşımlardan birinde ise mevcut veriseti eğitim ve test olacak şekilde iki parçaya ayrılır ve eğitim verileri modeli geliştirmek için kullanılırken test verileri sınıflandırma performansını ölçmek için kullanılır. Fakat bu yöntem genellikle büyük miktardaki verilerde daha iyi sonuçlar üretmektedir. Eğer veriler nispeten daha az sayıda ise bu durumda çapraz doğrulama adlı yöntem tercih edilir. Bu yöntemde model belirli bir veri grubunda yalnızca bir kere eğitilmez, onun yerine farklı veri parçaları için yinelemeli olarak birkaç model geliştirilir ve eğitilir. Örneğin veriler 10 parçaya ayrılır ve verilerin bir kısmı eğitim için kullanılırken bir kısmı da test için kullanılır. Bu işlem tüm veriler kullanılmasına kadar tekrar ettirilir. Modelin performansı ise her parçadaki model performanslarının ortalamasından oluşur.

2.4. Başarı Ölçütleri

Makine öğrenmesi algoritmalarının bir veri setinde yaptığı tahminde ne kadar başarılı bir sonuç sunduğunu ölçmek için bir takım analiz yöntemleri bulunmaktadır. Bu analiz yöntemlerinden sınıflandırma problemlerinde sıklıkla kullanılanlar doğru sınıflandırma oranı ve karmaşıklık matrisi yöntemleri şeklindedir. Sınıflandırma yöntemlerinin çalıştırılmasıyla elde edilen bulgulardan, olması gereken yani doğru sınıfta etiketlenen verilerin tüm örneklemin sayısına bölünmesiyle elde edilen oran doğru sınıflandırma oranıdır.

$$\text{Doğru Sınıflandırma Oranı} = \frac{\text{Doğru Sınıflandırılmış Örnek Sayısı}}{\text{Toplam Örnek Sayısı}}$$

Sık kullanılan diğer başarı ölçütü olan karmaşıklık matrisi ise sınıflandırmadaki başarının daha detaylı analiz edilmesi amacıyla kullanılmaktadır. Bu yöntem hata matrisi olarak da isimlendirilmektedir. Hata matrisine ait detaylı bilgi Tablo 2.1’de gösterilmektedir.

Tablo 2.1. Hata (karmaşıklık) Matrisi

		TAHMİN EDİLEN	
		Sınıf 1	Sınıf 2
GERÇEK DURUM	Sınıf 1	Gerçek Pozitif (GP)	Yanlış Negatif (YN)
	Sınıf 2	Yanlış Pozitif (YP)	Gerçek Negatif (GN)

Tablo 2.1’de gösterilen GP, YP, YN ve GN kavramlarının ne anlama geldiği aşağıda açıklanmıştır.

- **Gerçek Pozitif (GP):** Bu değer, gerçekte Sınıf 1’e ait olup tahminler sonucunda yine Sınıf 1’de olduğu tespit edilen yani doğru tahmin edilen örneklerin sayısıdır.
- **Gerçek Negatif (GN):** Bu ifade yanlışta yanlış demekle aynı durumu kapsar. Yani 0 olan değer 0 olarak tahmin edilmesidir.
- **Yanlış Pozitif (YP):** Bu durum, gerçek değeri 0 iken tahmin değerinin 1 olduğu yani yanlış tahmin edilenlerdir. Bir diğer ifade ile yanlışta doğru demek anlamına gelen tahminlerdir.
- **Yanlış Negatif (YN):** Doğruya yanlış demek anlamına gelen tahminlerdir.

Burada özetle, GP ve GN kapsamındaki tahminler doğru tahminler olup YP ve YN’ler ise yanlış yapılan tahminlerdir. Hata matrisindeki veriler kullanılarak doğruluk, duyarlık, kesinlik vb. birçok başarı ölçümleri hesaplanabilir. Esas amaç yapılan tahminde GP ve GN’lerin yani doğru tahminlerin sayısını arttırmaktır.

3. TRANSFER ÖĞRENME

Makine öğrenmesi yöntemleri, belirli bir problemin çözümünde bir veri setinin eğitilerek o veri setinden aranılan bir özelliğin veya parametrenin öğrenilmesi, tahmin edilmesi gibi amaçlar için kullanılır. Eldeki veri setinin spesifik olarak belirli bir problemin çözümünde kullanılması, makine öğrenmesi yöntemlerinin kullanım alanını ve kabiliyetlerini de doğal olarak sınırlı ve izoleli kılar. Çünkü eğitilen veri setinden elde edilen öğrenme deneyimi farklı bir amaç için tekrar kullanılamaz. Bu durum biraz da veri setinin toplanmasından kaynaklıdır. Makine öğrenmesinde kullanılan eğitim ve test veri setleri genelde ortak bir veri setinin paylaşılmasından elde edildiği için ortaya çıkan öğrenme deneyimi sadece ilgili veri setinde anlamlıdır ve başka benzerliği veya ortak yönü bulunan bir problemin çözümünde kullanılabilir değildir.

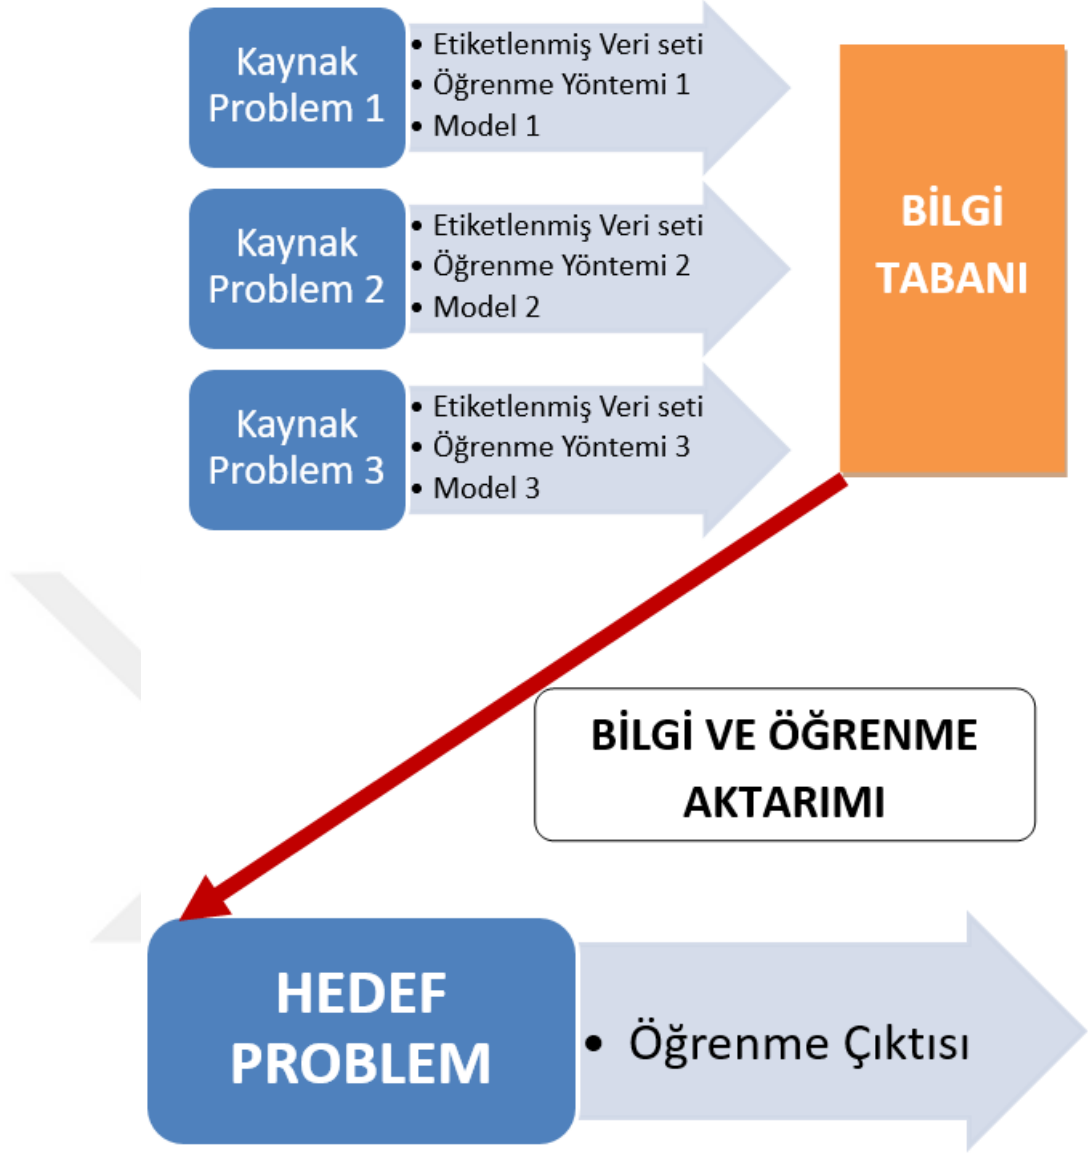
Günlük hayat problemlerinin çözümünde insanlar karşılaştıkları yeni bir durum karşısında önceki problem çözme yetenekleri ve bu problemlerin çözümünde kullandıkları bilgiler yardımıyla yeni probleme anında hızlıca alternatif çözümler üretebilmektedir. Bisiklet kullanabilen birinin daha büyük ve daha hızlı bir araç olarak motorsiklet kullanabilmesi, ya da otomobil kullanan bir sürücünün tır kullanımını öğrenmesi belirli bir bilgi ve deneyimi başka bir alanda kullanarak yeni durumda öğrenmeyi sürdürmeye örnek verilebilir. Yine insanın bildiği, tanıdığı bir hayvan türüne karşılık ilk defa gördüğü bir hayvanı bu türe benzetmesi veya yeni gördüğü hayvanın türüyle ilgili tahminde bulunması öğrenme deneyiminin farklı alanlarda sürekli kullanılabilmesine örnektir. Bu amaç için sayısız örnekler sıralanabilir. İnsandaki bu öğrenme deneyiminin farklı bir problem çözümünde kullanılabilmesi, bilgisayar bilimleri alanında tek bir probleme odaklanan makine öğrenmesi yaklaşımının transfer öğrenme yaklaşımına evrilmesinde ilham kaynağı olmuştur. İnsanın geçmiş bilgi ve deneyimlerinden öğrenmeyi sürdürme yeteneğinin bilgisayar sistemlerine aktarılması hedeflenen transfer öğrenme yaklaşımında da esas alınan belirli bir problemin çözümünde elde edilen öğrenmenin yeni bir problem çözümünde kullanılabilmek üzere aktarılmasıdır [33]. Transfer öğrenme, bir problemin çözümünde elde edilen bilgiyi kayıt altına alarak daha sonra farklı bir problemin çözümünde kullanmaya odaklanan, makine öğrenmesinde bir araştırma konusudur.

Transfer öğrenmede elde edilen öğrenmenin aktarılabilmesi, geleneksel makine öğrenmesi yöntemlerine göre bir takım avantajlar sağlamaktadır ve bu avantajları transfer öğrenmenin

tercih edilmesinde etkili olmaktadır. Transfer öğrenmenin geleneksel makine öğrenmesi yaklaşımlarına karşı sunmuş olduğu avantajlar aşağıda sıralanmıştır [34]:

- Makine öğrenmesinde her bir problemin çözümünde öğrenme süreci en baştan yürütülürken transfer öğrenmede daha önceden elde edilen öğrenmeden yararlanır.
- Önceden eğitilmiş modeller kullanıldığı için transfer öğrenmede eğitim süresi çok kısadır.
- Aktarılan öğrenme ile eğitilmiş model kullanıldığından daha az veri setinde daha yüksek başarı elde edilebilir.
- Eğitim için daha az donanım ve zaman kullanıldığından daha yüksek performans sağlanır.

Transfer öğrenmenin kullanılabilmesi için en az iki problemin varlığından söz etmek gerekir ki bunlardan biri çözülmesi istenilen ana problem olarak ifade edilen hedef problemdir. Hedef problemin çözümünde öğrenmenin esas alındığı kaynak problem(ler) ise diğer problem türünü oluşturur. Kaynak problem; hedef probleme göre daha çok veri setinin bulunduğu, bu veri setinin belirli bir makine öğrenmesi algoritması ile eğitilerek bir modelin sunulduğu ve hedef problemin çözümüne katkı olarak öğrenmenin aktarıldığı kaynaktır. Burada transfer öğrenmenin yüksek bir başarımlar sunabilmesi için bir takım kısıtlar bulunmaktadır. Kaynak problemin hedef problem ile benzerliği, kaynak problemden elde edilen öğrenilmiş modelde kullanılan veri setinin kalitesi ve miktarı transfer öğrenmenin başarısını doğrudan etkileyen faktörlerdir [35]. Transfer öğrenme yaklaşımının genel yapısı Şekil 2.3'te gösterilmektedir. Şekil 2.3 incelendiğinde kaynak problemlerin makine öğrenmesi yöntemleriyle çalıştırılarak elde edilen modellerinden oluşan bilgi tabanının çözülmesi hedeflenen probleme bilgi ve öğrenme deneyimi olarak aktarılarak kullanıldığı anlatılabilir.




Şekil 3.1. Transfer Öğrenme Model Yapısı

Derin öğrenme ve transfer öğrenme algoritmalarının temelini oluşturan evrişimli sinir ağı (CNN), hayvan görü sistemine dayanan, görüntünün özelliklerini belirgin hale getirmek için filtrelemenin kullanıldığı bir yaklaşımdır. Filtreleme işlemi ile görüntünün özelliklerini belirlemeye yarayan öznelikler tespit edilir. Bu filtrelerin farklı boyut ve değerlerde kullanılması ise belirgin olmayan özneliklerin ortaya çıkmasını kolaylaştırır [36]. Bu tez çalışmasında transfer öğrenmede Python platformundaki kütüphaneler kullanılmıştır. Bu algoritma yöntemlerine aşağıda alt başlıklar halinde kısaca değinilmiştir.

3.1.1. AlexNet

Bir evrişimli sinir ağı olan AlexNet'in mimarisi Şekil 2.4'te gösterilmektedir. AlexNet algoritmasında giriş görüntü verisinin boyutunun beş farklı evrişim katmanında uygulanan filtreler ile indirildiği, sondaki üç katmanda ise tahmin işleminin yapılabilmesi için önceki katmanlardan gelen özelliklerin birleştirilerek tek boyutlu bir vektör haline getirilen tam bağlantı (özellik) katmanı olduğu Şekil 2.4'ten de görülmektedir [37].



Şekil 3.2. AlexNet Convolutional Neural Network Layer Structure [38]

3.1.2. VGG (Visual Geometry Group)

ILSVRC-14 yarışmasında görüntü sınıflandırmadaki hata oranını %7.3'e düşürerek başarısını ortaya koyan görsel geometri gruplama (VGG) algoritması 19 evrişim katmanına kadar 6 farklı mimaride tasarlanmıştır. Kendisinden önceki derin öğrenme algoritmalarından farklı olarak VGG'de 2x2 ve 3x3 boyutlarındaki filtreler kullanılmıştır [36, 39]. VGG algoritması kullanılan katman sayısına göre isimlendirilmektedir. Örneğin 16 katmanlı bir yapı kullanılıyorsa VGG16, 19 katmanlı bir mimari kullanılmışsa bu algoritma VGG19 olarak ifade edilmektedir.

3.1.3. ResNet

Microsoft tarafından geliştirilen ResNet, 152 katmanı ile 2015 yılına kadar geliştirilen en derin mimariye sahip algoritma olmuştur. İnsanın görmedeki hata oranı yaklaşık %5 ile %10 arasındayken, %3,57 hata oranı ile görüntü sınıflandırmayı başaran ResNet bu başarısı nedeniyle 2015 yılındaki ImageNET ILSVRC yarışmasında birinci olmuştur [40, 41].

3.1.4. DenseNet

Bu mimaride ağ katmanları arasındaki bilgi akış yoğunluğu maksimum seviyededir. Çünkü DenseNet mimarisinde her katman kendisinden önceki katmanlardan aldığı girdi sayesinde oluşturduğu özellik haritalarını kendisinden sonra gelen katmana iletmektedir. Bu algoritmanın kullanımının sağladığı en büyük avantaj da her katmanda üretilen özelliğin sonraki katmanlara ulaşmasını sağlayarak elde edilen özelliklerin yeniden kullanılabilirliğini sağlamasıdır. DenseNet algoritmaları, kullanılan katman sayılarına göre DenseNet121, DenseNet169, DenseNet201 gibi farklı versiyonlarda kullanılabilir [42, 43].

3.1.5. EfficientNet

Bu model, bir grup evrişimli sinir ağı modeli olarak düşünülebilir. ImageNet yarışmasındaki sınıflandırma probleminde %85'e yakın bir doğruluk performansı göstermiştir. EfficientNet algoritmaları B0 ve B7 arasında isimlendirilmiş toplam sekiz model grubundan oluşmaktadır. Model numaraları arttıkça ilgili modelin hesaplayacağı parametre sayısı artmaz, aksine modelin ulaştığı doğruluk ciddi oranda artış göstermektedir. Bu modelde, çözünürlük, genişlik ve derinlik gibi parametrelerde ölçekleme yaparak verimliliği arttırmak amaçlanmaktadır [44].

3.1.6. Inception-V3

Google tarafından eğitilen ve geliştirilen bu mimari, filtreleme ve havuzlama işlemlerinin eş zamanlı yapılması prensibine dayanan Inception ağ yapısındadır ve toplam 42 katmana kadar oluşabilmektedir. Inception-V3 algoritmasında farklı boyut ve sayıdaki filtreler yeni bir filtrede birleştirilerek bir başlangıç modeli sunulmuş olur. Böyle bir tasarım sayesinde parametre sayısı ve hesaplama karmaşıklığı azaltıldığından görüntü sınıflandırmadaki en başarılı algoritmalar arasında bulunmaktadır [44].

3.1.7. MobileNet

Bu algoritma mobil ve gömülü platformlar için tasarlanmış olup popüler modellerden daha küçük boyuttadır ve daha yüksek performansta çalışmaktadır. MobileNet farklı derinlikler için ayrılabilir evrişimlerden oluştuğu için işlemleri çok daha hızlı yapabilir. Mimari özelliğinden dolayı MobileNet ile işlem hacmi ve parametre sayısı azaltılarak hesaplama karmaşıklığı

minimize edilebildiğinden güç ve donanım yönünden kısıtlı olan mobil ve gömülü platformlarda kullanılabilirlik yönünden tercih sebebi olmuştur [45, 46].

3.1.8. Xception

Google tarafından Inception mimarisinin daha da geliştirilmesiyle ortaya Xception modeli çıkmıştır. Bu model diğerlerine göre daha derin ve geniş bir mimaride tasarlanmıştır. Model giriş, orta ve çıkış akışları olmak üzere üç akıştan oluşur. Veriler giriş akışından geçtikten sonra sekiz defa tekrar eden orta akıştan geçerek çıkış akışına gelir. Xception modelinde evrişim katmanlarının tamamında normalizasyon işlemleri uygulanmaktadır [47].

3.1.9. NasNet

NasNet Google Brain takımı tarafından geliştirilen bir modeldir. Model boyutunun küçük olması ve az karmaşıklıkla iyi sonuçlar vermesi NasNet'in önemli bir avantajıdır. NasNet, sabit bir yapıda olmayıp dinamik olarak değişebilen hücre yapılarından oluşmaktadır. Evrişim işlemlerinin gerçekleştiği bu hücreler normal hücre ve indirgeme hücresi olmak üzere iki çeşittir. İndirgeme hücresinin normal hücreden farkı ise aldığı çıktının boyutlarını küçültmesidir [48].

4. BULGULAR


4.1. İstatistiksel Bulgular

Görüntü dosyalarının 1980 tane olması ve tümünün aynı klasör içinde yer almasından dolayı dosyalarda isimlendirme işlemi esnasında bir kural geliştirme zorunluluğu hasıl olmuştur. Bunun için dosya adlarında kişi numarası, cinsiyet, yaş ve görüntü numarası dosya adlarına yazılmış ve her biri alt çizgi ile ayrılmıştır. Bu dosyaların adındaki üçüncü parça olan cinsiyet verileri basit bir istatistiksel analize tabi tutulmuş ve aşağıdaki tabloda verilen durum ortaya çıkmıştır.

Tablo 4.1. Veri setindeki cinsiyetlerin dağılımı

Cinsiyet	Kişi Sayısı	Oran
Erkek	940	%47,48
Kadın	1040	%52,52
Toplam	1980	%100

Veriler arasında kadın deneklerin sayısı kısmen daha fazla olsa dahi birbirine yakın sayıda örnekler elde edilmiştir. Veri setindeki yaşların durumu incelendiğinde ise 3 ile 64 yaş aralığında değişen sayıda örnek olduğu görülecektir. Bu yaşlara ait örneklem dağılımı aşağıdaki grafikte görsel olarak verilmiştir. Bu grafiğin incelenmesi durumunda 20 yaş altında ve 40 yaş üstünde daha az örneklem elde edilmişken 20-40 yaş arasında daha çok örneklem elde edildiği gözlenmiştir. Buradaki sayılar kişileri değil kişilerden elde edilen görüntü sayılarını ifade etmektedir. Her deneğin sağ ve sol göz çevresinden 10'ar tane görüntüden toplam 20 görüntü elde edilmiştir. Bu nedenle grafikteki minimum değerler 20'den başlamakta olup 20'nin katları şeklindedir.



Şekil 4.1. Her bir yaştan kaç görüntü olduğunu gösteren grafik

4.2. Kişi Sınıflandırma Bulguları

Görüntüler 96 farklı kişiden elde edilmiştir. Bu görüntülerin özniteliklerinin çıkarılmasında 32 farklı transfer öğrenme algoritması kullanılmıştır. Her bir öznitelik çıkarma algoritmasından hangisinin öncelikle daha iyi performans gösterdiğini belirlemek için sınıflandırma algoritmalarından RandomForest adlı yöntem seçilmiş ve tüm öznitelikler bu yöntem ile sınıflandırılmıştır. Elde edilen doğruluk oranları ve yöntem adları doğruluk oranlarının küçükten büyüğe doğru sıralanmış olarak aşağıdaki tabloda verilmiştir. Burada verilerin eğitim ve test olarak ayrışmasında %30 test ve %70 eğitim olarak ayrışması kullanılmıştır. Burada 10-katlı çapraz doğrulama yöntemi işlemi 10 kez tekrarlayacağı ve işlem süresini uzatacağı için tercih edilmemiştir. Burada amaç yalnızca en iyi öznitelik çıkarım yöntemini belirlemektir.

Tablo 4.2. Farklı Transfer Öğrenme Algoritmalarının Doğruluk Oranları

Sıra No	Transfer Öğrenme Öznelik Çıkarma Algoritması	Doğruluk Oranı
1	InceptionResNetV2	0,304714
2	NASNetMobile	0,382155
3	InceptionV3	0,424242
4	NASNetLarge	0,436027
5	ResNet50V2	0,468013
6	DenseNet121	0,478114
7	MobileNet	0,508418
8	MobileNetV2	0,513468
9	Xception	0,521886
10	EfficientNetV2S	0,56229
11	AlexNet	0,572391
12	EfficientNetV2B2	0,582492
13	EfficientNetV2B0	0,585859
14	EfficientNetV2B1	0,604377
15	EfficientNetV2M	0,609428
16	DenseNet201	0,617845
17	EfficientNetV2B3	0,627946
18	VGG16	0,62963
19	EfficientNetB2	0,631313
20	EfficientNetB0	0,631313
21	EfficientNetV2L	0,631313
22	EfficientNetB3	0,639731
23	VGG19	0,639731
24	EfficientNetB6	0,648148
25	EfficientNetB5	0,649832
26	EfficientNetB1	0,651515
27	DenseNet169	0,656566
28	EfficientNetB4	0,658249
29	EfficientNetB7	0,681818
30	ResNet101	0,708754

31	ResNet152	0,712121
32	ResNet50	0,723906

Buradaki veriler için ResNet50 algoritması en yüksek başarıya sahip öznelik çıkarım yöntemi olduğu görülmüştür. Artık bu öznelikler farklı sınıflandırma algoritmaları için kullanılabilir. Bunun için 27 farklı sınıflandırma algoritması kullanılmış ve aşağıdaki tabloda verilen sonuçlar elde edilmiştir. Bu sonuçlar her bir yöntemin gruplanmış hali ile gösterilmiştir. RandomForest yönteminin yukarıdaki tabloya kıyasla farklı sonuç üretmesi kodların her çalıştırmada farklı parametreler ile sonuçlar üretmesinden kaynaklanmaktadır. Burada verilerin eğitim ve test olarak ayrışmasında %30 test ve %70 eğitim olarak ayrışması kullanılmıştır. Burada 10-katlı çapraz doğrulama yöntemi işlemi 10 kez tekrarlayacağı ve işlem süresini uzatacağı için tercih edilmemiştir. Burada amaç yalnızca en iyi sınıflandırma yöntemini belirlemektir. Bu tablo incelendiğinde 0,83 başarı oranı ile LinearSVC yöntemi en yüksek sonucu elde etmiştir. Diğer yöntemlerden birçoğu da bu değerlere yakın sonuçlar üretmişse de LinearSVC yöntemi tercih edilerek devam edilecektir.

Tablo 4.3. ResNet50 Özneliklerinin farklı sınıflandırma yöntemleri ile elde edilen sonuçlar

Grup	Sınıflandırma Yöntemi	Doğruluk	F-Ölçüsü	Duyarlılık	Kesinlik
discriminant_analysis	LinearDiscriminantAnalysis	0,8081	0,7785	0,7919	0,7900
discriminant_analysis	QuadraticDiscriminantAnalysis	0,0606	0,0641	0,0734	0,0762
ensemble	ExtraTreesClassifier	0,7298	0,6841	0,7187	0,6973
ensemble	RandomForestClassifier	0,7121	0,6664	0,7015	0,6931
ensemble	VotingClassifier	0,7096	0,6724	0,6972	0,7126
ensemble	HistGradientBoostingClassifier	0,6869	0,6675	0,7105	0,6726
ensemble	BaggingClassifier	0,5152	0,4840	0,5219	0,5326
ensemble	GradientBoostingClassifier	0,3561	0,3775	0,3659	0,4862
ensemble	AdaBoostClassifier	0,0253	0,0146	0,0342	0,0174
linear_model	LogisticRegressionCV	0,8359	0,8283	0,8493	0,8360
linear_model	RidgeClassifier	0,8283	0,8033	0,8192	0,8178
linear_model	RidgeClassifierCV	0,8283	0,8033	0,8192	0,8178
linear_model	LogisticRegression	0,8232	0,8213	0,8344	0,8376
linear_model	PassiveAggressiveClassifier	0,8081	0,7785	0,8065	0,7871
linear_model	SGDClassifier	0,7828	0,7606	0,7924	0,7831
linear_model	Perceptron	0,7601	0,7324	0,7733	0,7457
naive_bayes	BernoulliNB	0,6869	0,6697	0,6962	0,6954
naive_bayes	MultinomialNB	0,6793	0,6412	0,6547	0,6738
naive_bayes	ComplementNB	0,4621	0,4351	0,4664	0,5344

naive_bayes	GaussianNB	0,2753	0,2843	0,2890	0,4317
neighbors	KNeighborsClassifier	0,6717	0,6543	0,6730	0,7169
neighbors	NearestCentroid	0,6237	0,5871	0,5958	0,6329
neural_network	MLPClassifier	0,8030	0,7828	0,8052	0,7987
svm	LinearSVC	0,8384	0,8337	0,8493	0,8377
svm	SVC	0,6515	0,6358	0,6777	0,6786
tree	ExtraTreeClassifier	0,2348	0,2063	0,2242	0,2156
tree	DecisionTreeClassifier	0,0480	0,0340	0,0469	0,0332

Buraya kadar yapılan işlemler ile veriler %30 test ve %70 eğitim olarak parçalanmış ve en iyi öznitelik çıkarım algoritması ile en iyi sınıflandırma yönteminin bulunması amaçlanmıştır. En iyi öznitelik çıkarım algoritması olarak ResNet50 ve en iyi sınıflandırma algoritması olarak da LinearSVC yöntemi bulunmuştur. Burada verilerin eğitim ve test olarak parçalanmasında literatürde yaygın olarak tercih edilen ve tüm verileri hem eğitim hem de test olarak kullanan 10-katlı çapraz doğrulama yönteminin de kullanılmasındaki sonuçlar merak edilmiştir. Bu nedenle yapılan bu yöntemdeki sonuçlar da aşağıdaki tabloda verilen gibi elde edilmiştir.

Tablo 4.4. 10-katlı çapraz doğrulama sonuçları

Başarı Ölçütü	Oran
Doğruluk Oranı (Accuracy)	0,8352
Duyarlılık (Recall)	0,8421
Kesinlik (Precision)	0,8378
F-Ölçüsü (f1)	0,8268

Burada 96 kişiye ait verilerin karışıklık matrisi çok büyük boyutlarda olduğu için değerler okunamayacağından gösterilmemiştir. Elde edilen sonuçlar incelendiğinde 10-katlı çapraz doğrulama sonuçlarının %30-%70 ayrımlı durum ile çok yakın sonuçlar ürettiğini göstermektedir.

4.3. Cinsiyet Sınıflandırma Bulguları

Göz çevresi görüntülerinden 32 farklı öznitelik çıkarım yöntemi kullanılmıştır. Bu veriler bu kez de kişiye göre değil de kadın ya da erkek olma durumuna göre sınıflandırılmaya çalışılmıştır. Bir öncesine göre cinsiyet belirlemede farklı bir öznitelik

çıkarm algoritmasının daha başarılı olabileceği düşüncesiyle RandomForest sınıflandırma yöntemi ile tümü test edilmiştir. Aşağıdaki tabloda verilen sonuçlar elde edilmiştir.

Tablo 4.5. Farklı Transfer Öğrenme Algoritmalarının Doğruluk Oranları

Sıra No	Transfer Öğrenme Öznelik Çıkarma Algoritması	Doğruluk Oranı
1	ResNet152	0,915824916
2	EfficientNetB6	0,902356902
3	ResNet101	0,902356902
4	DenseNet201	0,897306397
5	EfficientNetB7	0,895622896
6	ResNet50	0,892255892
7	EfficientNetV2B1	0,892255892
8	EfficientNetB5	0,888888889
9	DenseNet169	0,885521886
10	EfficientNetV2M	0,885521886
11	EfficientNetB4	0,882154882
12	EfficientNetB3	0,882154882
13	EfficientNetB2	0,878787879
14	EfficientNetB0	0,878787879
15	VGG19	0,878787879
16	VGG16	0,878787879
17	EfficientNetV2L	0,875420875
18	EfficientNetV2B0	0,868686869
19	EfficientNetV2B3	0,865319865
20	Xception	0,838383838
21	EfficientNetV2B2	0,838383838
22	AlexNet	0,833333333
23	InceptionV3	0,823232323
24	MobileNet	0,814814815
25	ResNet50V2	0,814814815
26	MobileNetV2	0,813131313
27	NASNetMobile	0,730639731

28	InceptionResNetV2	0,718855219
29	EfficientNetB1	0,898989899
30	EfficientNetV2S	0,877104377
31	NASNetLarge	0,82996633
32	DenseNet121	0,82996633

En iyi öznitelik çıkarım algoritması bulunduğu için bu kez bu algoritma ile en yüksek başarıya sahip sınıflandırma algoritması bulunmaya çalışılacaktır. Bunun için de 28 farklı sınıflandırma yöntemi ile bu öznitelikler test edilmiş ve elde edilen sonuçlar aşağıdaki tabloda verilmiştir. MLPClassifier adlı sınıflandırma yöntemi %96,46 oranında başarılı sınıflandırma elde etmiştir. En yüksek başarı elde edilen bu yöntemin bir diğer adı yapay sinir ağıdır. Diğer yöntemlerden de bu değerlere yakın sonuçlar üretenleri vardır.

Tablo 4.6. ResNet152 Özniteliklerinin farklı sınıflandırma yöntemleri ile elde edilen sonuçlar

Grup	Sınıflandırma Yöntemi	Doğruluk	F-Ölçüsü	Duyarlılık	Kesinlik
discriminant_analys	LinearDiscriminantAnalysis	0,8359	0,8356	0,8366	0,8355
discriminant_analys	QuadraticDiscriminantAnalysis	0,6869	0,6795	0,6986	0,7280
ensemble	HistGradientBoostingClassifier	0,9571	0,9570	0,9577	0,9566
ensemble	GradientBoostingClassifier	0,9419	0,9416	0,9412	0,9422
ensemble	ExtraTreesClassifier	0,9268	0,9262	0,9248	0,9290
ensemble	AdaBoostClassifier	0,9242	0,9241	0,9252	0,9238
ensemble	VotingClassifier	0,9217	0,9210	0,9194	0,9247
ensemble	RandomForestClassifier	0,9091	0,9086	0,9081	0,9093
ensemble	BaggingClassifier	0,8712	0,8703	0,8694	0,8722
linear_model	PassiveAggressiveClassifier	0,9444	0,9444	0,9461	0,9444
linear_model	LogisticRegression	0,9419	0,9419	0,9437	0,9421
linear_model	Perceptron	0,9419	0,9418	0,9431	0,9416
linear_model	LogisticRegressionCV	0,9394	0,9394	0,9413	0,9397
linear_model	SGDClassifier	0,9394	0,9390	0,9382	0,9403
linear_model	RidgeClassifier	0,9192	0,9191	0,9201	0,9188
linear_model	RidgeClassifierCV	0,9192	0,9191	0,9201	0,9188
naive_bayes	BernoulliNB	0,7551	0,7509	0,7500	0,7591
naive_bayes	ComplementNB	0,7247	0,7233	0,7230	0,7238
naive_bayes	MultinomialNB	0,7222	0,7206	0,7203	0,7213
naive_bayes	GaussianNB	0,6540	0,6451	0,6661	0,6932
neighbors	KNeighborsClassifier	0,9444	0,9442	0,9442	0,9442

neighbors	NearestCentroid	0,7020	0,6976	0,6972	0,7032
neural_network	MLPClassifier	0,9646	0,9646	0,9657	0,9642
svm	NuSVC	0,9394	0,9390	0,9382	0,9403
svm	LinearSVC	0,9369	0,9368	0,9392	0,9379
svm	SVC	0,9268	0,9261	0,9245	0,9298
tree	DecisionTreeClassifier	0,7348	0,7338	0,7337	0,7339
tree	ExtraTreeClassifier	0,7197	0,7184	0,7182	0,7187

Buraya kadar hem RandomForest ile tüm özniteliklerin sınıflandırılmasında hem de ResNet152 özniteliklerinin farklı sınıflandırma yöntemleri ile test edilmesinde veriler %30 test, %70 eğitim olarak ayrıştırılmıştır. 10-katlı çapraz doğrulama yöntemi kullanıldığında sonuçların değişip değişmeyeceği merak edildiğinden bu kez de veriler bu şekilde ayrıştırılarak denenmiştir. Elde edilen sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 4.7. 10-katlı çapraz doğrulama sonuçları

Başarı Ölçütü	Oran
Doğruluk Oranı (Accuracy)	0.964123468184382
Duyarlılık (Recall)	0.9641793993632571
Kesinlik (Precision)	0.9646035623101692
F-Ölçüsü (f1)	0.9639744806181051

Elde edilen sonuçların karışıklık matrisi aşağıdaki şekilde verilmiştir. Matris incelendiğinde toplam 1980 örnek içinden yalnızca 71 tanesinin yanlış sınıflandırıldığı görülecektir.



Şekil 4.2. Cinsiyet sonuçları karışıklık matrisi

4.4. Yaş Sınıflandırma Bulguları

Görüntü verileri farklı yaşlardaki deneklere aittir. Bu yaşlar 39 farklı türde olup 3-64 arasında değişmektedir. Bu kadar farklı türde olmasına karşın göz çevresine bakarak kişilerin yaşlarının tahmin edilip edilmeyeceği merak edilmiştir. Öncelikle farklı öznitelik çıkarma algoritmaları ile yaşlar RandomForest yöntemi ile sınıflandırılmıştır. Eğitim verisi olarak rastgele seçilmiş %70 ve geriye kalan %30'unun da test verisi olduğu durum için elde edilen sonuçlar aşağıdaki tabloda verilmiştir. Yaş etiketleri de tıpkı kişi etiketleri gibi ResNet50 öznitelik çıkarım algoritması ile en yüksek sonuçları üretmiştir. Her ne kadar diğer algoritmalar da yakın değerler üretmişse de buradaki çalışmada ResNet50 algoritması tercih edilerek devam edilecektir.

Tablo 4.8. Farklı Transfer Öğrenme Algoritmalarının Doğruluk Oranları

Sıra No	Transfer Öğrenme Öznelik Çıkarma Algoritması	Doğruluk Oranı
1	InceptionResNetV2	0,338384
2	NASNetMobile	0,373737
3	InceptionV3	0,427609
4	MobileNetV2	0,434343
5	ResNet50V2	0,43771
6	DenseNet121	0,441077
7	NASNetLarge	0,454545
8	Xception	0,496633
9	MobileNet	0,521886
10	AlexNet	0,538721
11	EfficientNetV2B2	0,575758
12	EfficientNetV2S	0,584175
13	EfficientNetV2B0	0,599327
14	EfficientNetV2M	0,614478
15	EfficientNetB2	0,621212
16	EfficientNetB0	0,624579
17	EfficientNetV2B1	0,62963
18	EfficientNetV2B3	0,632997
19	DenseNet169	0,638047
20	DenseNet201	0,639731
21	VGG16	0,641414
22	EfficientNetV2L	0,644781
23	EfficientNetB3	0,649832
24	EfficientNetB5	0,651515
25	EfficientNetB1	0,651515
26	EfficientNetB6	0,666667
27	ResNet101	0,666667
28	VGG19	0,666667
29	EfficientNetB4	0,675084
30	EfficientNetB7	0,685185

31	ResNet152	0,70202
32	ResNet50	0,715488

ResNet50 adlı öz nitelik çıkarma algoritması buradaki görüntüler için en başarılı sonuçları üreten algoritma olmuştur. Artık bu algoritma ile en yüksek başarıya ulaşılabilecek sınıflandırma algoritması test edilebilir. Bunun için 27 farklı sınıflandırma yöntemi kullanılmış ve sonuçlar aşağıdaki tablodaki gibi olmuştur.

Tablo 4.9. ResNet152 Öz niteliklerinin farklı sınıflandırma yöntemleri ile elde edilen sonuçlar

Grup	Sınıflandırma Yöntemi	Doğruluk	F-Ölçüsü	Duyarlılık	Kesinlik
discriminant_analysis	LinearDiscriminantAnalysis	0,7753	0,8061	0,8064	0,8265
discriminant_analysis	QuadraticDiscriminantAnalysis	0,0985	0,0997	0,1025	0,1490
ensemble	VotingClassifier	0,7677	0,8067	0,7994	0,8283
ensemble	ExtraTreesClassifier	0,7500	0,7717	0,7522	0,8466
ensemble	HistGradientBoostingClassifier	0,7475	0,7512	0,7611	0,7693
ensemble	RandomForestClassifier	0,7323	0,7748	0,7542	0,8490
ensemble	GradientBoostingClassifier	0,5682	0,5663	0,5486	0,6805
ensemble	BaggingClassifier	0,5455	0,5741	0,5734	0,6393
ensemble	AdaBoostClassifier	0,0985	0,0388	0,0769	0,0334
linear_model	RidgeClassifier	0,8712	0,8982	0,8940	0,9172
linear_model	RidgeClassifierCV	0,8712	0,8982	0,8940	0,9172
linear_model	LogisticRegressionCV	0,8636	0,8956	0,8984	0,9056
linear_model	PassiveAggressiveClassifier	0,8561	0,8911	0,8935	0,9056
linear_model	LogisticRegression	0,8131	0,8345	0,8395	0,8494
linear_model	SGDClassifier	0,8106	0,8439	0,8495	0,8866
linear_model	Perceptron	0,7222	0,7708	0,7765	0,8282
naive_bayes	BernoulliNB	0,5480	0,6366	0,6221	0,7134
naive_bayes	MultinomialNB	0,5328	0,6275	0,6392	0,6749
naive_bayes	GaussianNB	0,4848	0,4789	0,4630	0,5884
naive_bayes	ComplementNB	0,3687	0,3617	0,3779	0,5298
neighbors	KNeighborsClassifier	0,7525	0,7717	0,7831	0,7948
neighbors	NearestCentroid	0,4495	0,5377	0,5898	0,5524
neural_network	MLPClassifier	0,8384	0,8628	0,8593	0,8856
svm	LinearSVC	0,8763	0,9102	0,9099	0,9203
svm	SVC	0,6389	0,6524	0,6387	0,7621
tree	ExtraTreeClassifier	0,2525	0,2467	0,2532	0,2649
tree	DecisionTreeClassifier	0,1465	0,0882	0,1092	0,0900

Daha önceki kişi tanımada olduğu gibi burada da en başarılı sınıflandırma algoritması %87,63 ile LinearSVC olmuştur. Buraya kadar yapılan analizlerde veriler eğitim için %70 ve test için %30 olacak şekilde rastgele seçilmiştir. Çok fazla yöntem ile test edildiğinden hızlı sonuçlar üretmesi için bu yöntem tercih edilmiştir. Fakat 10-katlı çapraz doğrulama yöntemi ile verilerin ayrıştırılması durumunda verilerin tümü hem test hem de eğitim için kullanılmaktadır. Bu nedenle de bu verilerin 10-katlı çapraz doğrulama ile ayrıştırılması sonrası testler yapılmış ve elde edilen sonuçlar aşağıdaki tabloda sunulmuştur.

Tablo 4.10. 10-katlı çapraz doğrulama sonuçları

Başarı Ölçütü	Oran
Doğruluk Oranı (Accuracy)	0.7756165718094652
Duyarlılık (Recall)	0.8275885225885226
Kesinlik (Precision)	0.8425287196081509
F-Ölçüsü (f1)	0.8160964372282458

Kişi tanıma sonuçlarında verilerin 10-katlı çapraz doğrulama ile test edilmesi ve %30-%70 ayrıştırma ile test edilmesi arasında çok yüksek farklılıklar görülmemiştir. Fakat burada yüksek bir farklılık görülmüştür. Bu durumun nedenleri arasında verilerin eğitim ve test ayrışmasında rastgele seçilmesi vardır. Bu rastgelelik bazen iyi tahmin edilen verileri test grubunda tutabilmekte ve daha yüksek başarılı sonuçlar üretebilmektedir. 10-katlı çapraz doğrulama ile tüm veriler hem eğitim hem de test olarak kullanılmış ve bu rastgelelik durumu ortadan kaldırılmıştır. Böylece %87,63 doğruluk oranı varken %77,56 doğruluk oranı elde edilmiştir. Burada da 39 farkı yaş değeri olduğu için karışık matrisindeki değerler okunamayacağından gösterilmemiştir.

5. TARTIŞMA VE SONUÇ

Bilgisayar bilimlerinde yapay zekânın bir alt grubunu oluşturan makine öğrenmesi yöntemleri ile analiz edilmesi gereken çok sayıda parametre ve veri setini sürdürmek için ihtiyaç duyulan karar verme süreçlerinin yönetilebilmesi mümkün hale gelmiştir. Bu sayede insanların el yordamıyla çözmek zorunda olduğu bir problem veya verilmesi gereken bir karar için tahminde bulunmada verilerin analiz edilerek bir örüntü elde edilebilmesi veya verilerin birbiriyle ilişkilerinin açıklanması oldukça kolaylaşmıştır. Makine öğrenmesi yöntemlerinin kullanılarak elde edilen bilgi ve deneyimlerin bilgisayarlı öğrenme olarak başka problemlerin çözümünde kullanılması ise öğrenmenin transfer edilmesi ile mümkündür. Bu durumda geçmiş deneyim ve öğrenmeler yeni ve daha farklı benzer problemlerin çözümünde kullanılabilir. Bu ihtiyaç, bilgisayar sistemleri tarafından elde edilen öğrenmenin transfer edilmesiyle daha büyük ve karmaşık problemlerin çözümünü verimli hale getirmiştir. Eğitilmiş veri setlerinin ve öğrenilmiş özelliklerin yeni problem üzerinde hızlıca kullanılabilmesi ise daha karmaşık ve zaman alıcı bu problemin çözümünde zaman ve donanım kaynaklarının kullanımında verimlilik avantajı sağlarken aynı zamanda da daha az büyüklükteki benzer veri seti ile problemi çözme imkanı sunmaktadır.

Yapılan çalışmada kişilerin göz çevresi görüntülerinden yaş, cinsiyet ve kişinin sınıflandırılması amaçlanmıştır. Bu amaç için 96 farklı kişiden elde edilen göz görüntüleri kullanılmıştır. Öncelikle 32 farklı transfer öğrenme algoritması kullanılarak göz görüntülerini tanımlamada kullanılacak özniteliklerin çıkarımı sağlanmıştır. Daha sonra özniteliklerin elde edilmesiyle kişileri tanımlamak amacıyla RandomForest algoritması kullanılarak göz görüntüleri sınıflandırılmıştır. Veri setinde öznitelik çıkarmada en yüksek başarıyı gösteren algoritma ResNet50 algoritması olmuştur. Çalışmanın devamında çıkarılan öznitelikler kullanılarak sınıflandırma algoritmaları çalıştırılmıştır. 27 farklı sınıflandırma algoritmasının kullanıldığı bu aşamada LinearSVC yöntemi kişileri sınıflandırmada en yüksek başarı oranını sunarak en iyi performansı gösteren algoritma olmuştur.

Göz çevresi görüntülerinden kadın ve erkek olarak cinsiyet sınıflandırması için öznitelik belirlemede ResNet152 algoritması en yüksek doğruluk oranını göstermiştir. ResNet152 algoritmasıyla belirlenen öznitelikler kullanılarak göz görüntülerinden cinsiyet için sınıflandırma yapıldığında ise MLPClassifier yöntemi (yapay sinir ağları) ile en yüksek doğruluk oranına ulaşılmıştır.

Yaş etiketleri için de kişi sınıflandırmada olduğu gibi öznitelik çıkarma aşamasında ResNet50 algoritması, yaş sınıflandırmada da LinearSVC algoritması en iyi sonuçları sunan algoritmalar olmuştur.

Yapılan çalışmada, kişileri, kişilerin cinsiyet ve yaş durumlarını tanımlamada bir biyometrik tanıma sisteminde göz görüntülerinin kaynak olarak kullanılabilmesi gösterilmiştir. Bu amaçla yapılan sınıflandırma çalışmalarında en yüksek başarı oranı sırasıyla yaş, kişi ve cinsiyet sınıflandırmada elde edilmiştir. Bu başarı oranları sırasıyla %96,41, %83,52 ve %77,56 olarak hesaplanmıştır. Yaş konusunda bu denli yüksek bir başarı sağlanmasının, insanlarda yaştaki değişimlere paralel olarak göz çevresinde de yapısal değişikliklerin meydana gelmesinden kaynaklandığı söylenebilir. Yine ilerleyen yaşlardan dolayı gözün damar ve sinir yapılarında göz görüntüsüne yansıtacak değişimlerin gözlenmesi muhtemel olduğundan yaş, görüntüden elde edilebilecek anlamlı bir tanımlama yöntemi olarak görülmüştür. Cinsiyet konusunda sadece göz görüntüsünden insanın bir kişinin cinsiyetini doğru tahmin etme olasılığı %50 iken transfer öğrenme yaklaşımıyla elde edilen performans, göz görüntülerinin cinsiyet tanımlamada doğru bir araç olarak kullanılabilmesini göstermektedir. Yapılan çalışmada göz görüntüleri elde edilen kişilerin genellikle 20-40 yaş altında olması araştırmanın bir kısıtı gibi görülebilir. Ancak buna rağmen yaşlar arasındaki farklılıkların görüntü üzerinde öznitelikler olarak tespit edilebildiği inkar edilemez bir gerçektir. Çalışmadaki kadın ve erkeklerin sayısının birbirlerine yakın olması ise cinsiyet konusundaki yüksek doğru sınıflandırma oranı için önemli bir durumdur. Çünkü veri sayısının belirli bir nitelikte yığılması, yapılan sınıflandırmanın performansı konusunda yanıltıcı olabilir.

Yapılan çalışmanın literatürdeki benzerleriyle olan ilişkilerinden yola çıkılarak nasıl bir boşluğu doldurduğu ve ne gibi yenilikler sunduğunu vurgulanmak gerekirse; literatürde genellikle iris tanıma veya göz bölgelerini tanıma üzerinde çalışmalar yapıldığı görülmektedir. Gözün kendi görüntüsünden kişi tanıma çalışmaları genelde iris tanıma yöntemiyle yapılmaktadır. Çanak [49], yaptığı tez çalışmasında göz çevresindeki kırışıklıkların sınıflandırmıştır. Araştırmacı 5 kadın ve 5 erkekte oluşan gönüllülerin sağ ve sol göz çevreleri ile alınlarının görüntüleri üzerinde çalışma yapmıştır. Araştırmacı kırışıklıkları sınıflandırmada en çok %63 doğruluk oranına ulaşmıştır. Yapılan çalışmadaki başarı oranları Çanak'ın çalışmasından oldukça yüksektir. Ayrıca bu çalışmada kullanılan veri setindeki kayıt sayısı Çanak'ın kullandığı veri setinden de oldukça fazladır. Bayraktar,

[50] yaptığı çalışmada 100 kişiden oluşan hazır bir veri seti olan UBIRIS'i kullanarak irisin kaotik yapısını analiz etmiştir. Yapılan bu çalışmada ise hazır bir veri seti kullanmak yerine gönüllülerden toplanan 1980 adet göz görüntüsünden oluşan veri seti diğer araştırmacıların da kullanımına sunulurken literatüre katkı sağlanmıştır. Öz, [51] derin sinir ağlarını kullanarak göz fotoğraflarından gözün sklera, iris, göz ve arka plan olarak sınıflandırılmasını amaçladığı çalışmasında 1660 adet görüntüsünden bir veri seti oluşturmuştur. Bu çalışmada göz, bölümlerine göre sınıflandırıldığından kişileri tanıma yönünden herhangi bir inceleme yapılmamıştır. Bircan, [52] yaptığı çalışmada Casia iris veritabanındaki verileri kullanarak iris tanıma yapmıştır. Bu çalışmada Bircan'ın çalışmasından farklı olarak hem hazır bir veri seti kullanılmamış olup kendi veri setimiz oluşturulmuştur hem de literatürde daha yaygın çalışılan iris tanıma yerine gözün kendi görüntüsü üzerinden bir sınıflandırma yapılmıştır.

Biyometrik tanımda kullanılan sistemlerin neredeyse hepsinde kullanılan donanım veya biyometrik özellikten kaynaklanan çeşitli dezavantajlar bulunmaktadır. Bu dezavantajlardan bazıları bu çalışmanın giriş bölümünde açıklanmıştır. Bu çalışma ile özel bir donanım veya ekipman kullanmadan, sadece akıllı telefon kamerası ile belirli mesafeden elde edilen göz görüntülerinden kişilerin yüksek doğrulukla tanımlanabileceği anlatılmıştır. Yapılan çalışma ile karmaşık ve pahalı donanımlar gerektiren biyometrik tanıma sistemlerinin sadece yüksek çözünürlüklü bir kamera yardımıyla göz görüntülerinin elde edilebildiği daha basit donanımlarla daha uygun maliyetlerle geliştirilebilmesine bir yol gösterilmiştir. Böylelikle geliştirilen daha ucuz sistemlerin daha fazla kullanıcıya ulaşması ve toplumda güvenlik ve doğrulama amacıyla biyometrik tanıma sistemlerinin kullanımının yaygınlaşmasına olumlu bir katkı sağlanmıştır. Ayrıca kamusal otoritelerin iç ve dış güvenlik için sadece göz görüntülerini kullanarak bile oluşturulacak veri tabanları sayesinde kişileri tanımda yeni, kolay ve verimli sistemler geliştirebilmesi için yapılan çalışma ile ilgili araştırmacılara, uzmanlara ve hükümet yöneticilerine farklı bir bakış açısı sunulmuştur. İlerleyen çalışmalarda daha fazla katılımcıdan elde edilen göz görüntüleri kullanılarak sınıflandırma çalışmaları yapılabilir. Ayrıca diyabet, hipertansiyon gibi kronik rahatsızlıkları olan kişilerin veya hastalıkların göz görüntüsünden tespit edilebilmesi için hasta ve sağlıklı kişiler üzerinde araştırmalar yürütülebilir. Göz ve göz çevresine ait görüntülerin herhangi bir kamera ile kolaylıkla temin edilebildiği için hem sağlık hem de bilişim alanında göz tanımanın kullanılabilmesi için yapılan deneysel çalışmalar araştırmacılara ve literatüre katkı sağlamaktadır.

KAYNAKLAR

1. Jain, A.K., P. Flynn, and A.A. Ross, *Handbook of biometrics*. 2007: Springer Science & Business Media.
2. Hidimođlu, K., *Web kamera kullanımı ile parmak izi tanıma ve kimlik tespiti doğrulama*. 2010, Fen Bilimleri Enstitüsü.
3. Ergen, B. and A. Çalışkan. *Biyometrik Sistemler ve El Tabanlı Biyometrik Tanıma Karakteristikleri*. in *6th International Advanced Technologies Symposium (IATS'11)*. 2011.
4. Maltoni, D., et al., *Handbook of Fingerprint Recognition*. SpringerVerlag New York. Inc., Secaucus, NJ, USA, 2003.
5. ŞAN, S., *Parmak damar tanıma teknolojisi/Finger vein identification technology*. 2013.
6. Hadid, A., et al., *Biometrics systems under spoofing attack: an evaluation methodology and lessons learned*. IEEE Signal Processing Magazine, 2015. **32**(5): p. 20-30.
7. Nguyen, K., et al., *Long range iris recognition: A survey*. Pattern Recognition, 2017. **72**: p. 123-143.
8. Franz-Odendaal, T.A. and M.K. Vickaryous, *Skeletal elements in the vertebrate eye and adnexa: morphological and developmental perspectives*. Developmental dynamics: an official publication of the American Association of Anatomists, 2006. **235**(5): p. 1244-1255.
9. Clinic, C. *Eye Anatomy*. 2022 [04.06.2022]; Available from: <https://my.clevelandclinic.org/health/body/21823-eyes>.
10. Malkoç, İ., *Göz Küresinin Tabakaları: Anatomik ve Histolojik Bir Derleme*. Eurasian J Med, 2006. **38**: p. 124-129.
11. Jaimes, A., et al. *Using human observer eye movements in automatic image classifiers*. in *Human Vision and Electronic Imaging VI*. 2001. SPIE.
12. Daugman, J.J.I.T.o.S., Man, and P.B. Cybernetics, *New methods in iris recognition*. 2007. **37**(5): p. 1167-1175.
13. Cerme, G.N. and M. Karakaya. *3D iris structure impact on iris recognition*. in *2015 23rd Signal Processing and Communications Applications Conference (SIU)*. 2015. IEEE.
14. Zhang, M., Z. Sun, and T. Tan. *Deformable DAISY matcher for robust iris recognition*. in *2011 18th IEEE international conference on image processing*. 2011. IEEE.
15. Azimi, M., S.A. Rasoulinejad, and A. Pacut. *The effects of gender factor and diabetes mellitus on the iris recognition system's accuracy and reliability*. in *2019 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*. 2019. IEEE.
16. Wang, C., et al., *Towards complete and accurate iris segmentation using deep multi-task attention network for non-cooperative iris recognition*. IEEE Transactions on information forensics and security, 2020. **15**: p. 2944-2959.
17. Bakshi, K.A., B. Prasad, and K. Sneha. *An efficient iris code storing and searching technique for Iris Recognition using non-homogeneous Kd tree*. in *2015 International Conference on Emerging Research in Electronics, Computer Science and Technology (ICERECT)*. 2015. IEEE.

18. Gangwar, A. and A. Joshi. *DeepIrisNet: Deep iris representation with applications in iris recognition and cross-sensor iris recognition*. in *2016 IEEE international conference on image processing (ICIP)*. 2016. IEEE.
19. Dong, W., et al. *Quality-based dynamic threshold for iris matching*. in *2009 16th IEEE International Conference on Image Processing (ICIP)*. 2009. IEEE.
20. Devi, C.N. *Automatic segmentation and recognition of iris images: With special reference to twins*. in *2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN)*. 2017. IEEE.
21. Sharkas, M. *A neural network based approach for iris recognition based on both eyes*. in *2016 SAI Computing Conference (SAI)*. 2016. IEEE.
22. Tan, C.-W. and A. Kumar. *Integrating ocular and iris descriptors for fake iris image detection*. in *2nd International Workshop on Biometrics and Forensics*. 2014. IEEE.
23. Vatsa, M., et al. *Quality-based fusion for multichannel iris recognition*. in *2010 20th International Conference on Pattern Recognition*. 2010. IEEE.
24. Zhang, X., Z. Sun, and T. Tan. *Hierarchical fusion of face and iris for personal identification*. in *2010 20th International Conference on Pattern Recognition*. 2010. IEEE.
25. Jalilian, E., M. Karakaya, and A. Uhl. *End-to-end off-angle iris recognition using cnn based iris segmentation*. in *2020 International Conference of the Biometrics Special Interest Group (BIOSIG)*. 2020. IEEE.
26. Sun, Z., et al., *Iris image classification based on hierarchical visual codebook*. IEEE Transactions on pattern analysis and machine intelligence, 2013. **36**(6): p. 1120-1133.
27. Frigerio, E., et al. *Correction method for nonideal iris recognition*. in *2012 19th IEEE International Conference on Image Processing*. 2012. IEEE.
28. Gale, A.G. and S.S. Salankar. *Evolution of performance analysis of iris recognition system by using hybrid methods of feature extraction and matching by hybrid classifier for iris recognition system*. in *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*. 2016. IEEE.
29. Dillak, R.Y. and M.G. Bintiri. *A novel approach for iris recognition*. in *2016 IEEE Region 10 Symposium (TENSYP)*. 2016. IEEE.
30. Popplewell, K., et al. *Multispectral iris recognition utilizing hough transform and modified LBP*. in *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2014. IEEE.
31. Ng, T.W., T.L. Tay, and S.W. Khor. *Iris recognition using rapid Haar wavelet decomposition*. in *2010 2nd International Conference on Signal Processing Systems*. 2010. IEEE.
32. Danlami, M., et al. *Comparing the legendre wavelet filter and the Gabor wavelet filter for feature extraction based on Iris recognition system*. in *2020 IEEE 6th International Conference on Optimization and Applications (ICOA)*. 2020. IEEE.
33. Devhunteryz. *Transfer Öğrenme*. 2022 30.05.2022]; Available from: <https://devhunteryz.wordpress.com/2018/07/28/transfer-ogrenimi-transfer-learning/>.
34. Çelik, S., *Özellik Optimizasyonu Yapılan Beyin Manyetik Rezonans Görüntülerindeki Tümörlü Dilimlerin Transfer Öğrenmesi İle Tespiti*, in *Lisansüstü Eğitim Enstitüsü*. 2020, Kütahya Dumlupınar Üniversitesi: Kütahya.
35. Yüksel, E., *Transfer Öğrenme Kullanılarak Yapay Arı Koloni Programlama*, in *Fen Bilimleri Enstitüsü*. 2019, Erciyes Üniversitesi: Kayseri.
36. Doğan, F. and İ. Türkoğlu, *Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme*. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 2019. **10**(2): p. 409-445.

37. BAYRAM, F., *Derin öğrenme tabanlı otomatik plaka tanıma*. Politeknik Dergisi, 2020. **23**(4): p. 955-960.
38. Alruwaili, M., et al., *An efficient deep learning model for olive diseases detection*. International Journal of Advanced Computer Science and Applications, 2019. **10**(8): p. 486-492.
39. Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
40. Özkan, İ. and E. Ülker, *Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri*. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 2017. **6**(3): p. 85-104.
41. Wu, S., S. Zhong, and Y. Liu, *Deep residual learning for image steganalysis*. Multimedia tools and applications, 2018. **77**(9): p. 10437-10453.
42. ERGÜN, E. and K. KILIÇ, *Derin Öğrenme ile Artırılmış Görüntü Seti üzerinden Cilt Kanseri Tespiti*. Black Sea Journal of Engineering and Science: p. 192-200.
43. Huang, G., et al. *Densely connected convolutional networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
44. Uçar, M., *Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti*. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 2021. **23**(68): p. 521-529.
45. GÖKALP, S. and İ. AYDIN, *Farklı Derin Sinir Ağı Modellerinin Duygu Tanımadaki Performanslarının Karşılaştırılması*. Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 2021. **2**(1): p. 35-43.
46. Howard, A.G., et al., *Mobilenets: Efficient convolutional neural networks for mobile vision applications*. arXiv preprint arXiv:1704.04861, 2017.
47. Akgözlüoğlu, K., *Transfer Öğrenmesi Tekniği Tabanlı Derin Öğrenme Yöntemiyle Ürün Tanıma*, in *Fen Bilimleri Enstitüsü*. 2021, Manisa Celal Bayar Üniversitesi: Manisa.
48. Balga, M.K., *Tatil Evlerindeki Odaların Derin Öğrenme İle Sınıflandırılması ve Uygulaması*, in *Fen Bilimleri Enstitüsü*. 2020, Selçuk Üniversitesi: Konya.
49. Çanak, B., *ALINDA VE GÖZ KENARLARINDA YER ALAN KIRIŞIKLIKLARIN SINIFLANDIRILMASI*, in *Fen Bilimleri Enstitüsü*. 2017, İstanbul Teknik Üniversitesi: İstanbul.
50. Bayraktar, H.K., *GÖZ İRİS GÖRÜNTÜLERİNDE KAOTİK YAPININ ANALİZİ*, in *Fen Bilimleri Enstitüsü*. 2018, Yalova Üniversitesi: Yalova.
51. Öz, M., *DERİN SİNİR AĞLARI KULLANILARAK GÖZ BÖLÜTLEMESİ*, in *Doğa ve Uygulamalı Bilimler Enstitüsü*. 2021, Akdeniz Üniversitesi: Antalya.
52. Bircan, A., *K-TDA SÖZLÜK ÖĞRENMESİ İLE GÖRÜNTÜ ZENGİNLEŞTİREREK İRİS TANIMA*, in *Lisansüstü Eğitim Enstitüsü*. 2021, Konya Teknik Üniversitesi: Konya.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Yasr Mahdi HAMA RASHID
Doğum Yeri	
Uyruğu	<input type="checkbox"/> T.C. <input checked="" type="checkbox"/> Diğer: Irak
E-Posta Adresi	
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	Tikrit Üniversitesi
Fakülte	Bilgisayar ve Matematik Bilimleri Fakültesi
Bölümü	Bilgisayar Bilimleri
Mezuniyet Yılı	2015

Yüksek Lisans	
Üniversite	Kırşehir Ahi Evran Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	İleri Teknolojiler Ana Bilim Dalı
Programı	İleri Teknolojiler Tezli Yüksek Lisans
Mezuniyet Tarihi	2021