



**T.C.
DÜZCE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EVRIŞİMSEL SINIR AĞLARI KULLANARAK PARMAK UCU
GÖRÜNTÜLERİNDEN CİNSİYET TAHMİNLEMESİ**

KEREM SIRMA

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
PROF. DR. PAKİZE ERDOĞMUŞ**

DÜZCE, 2021

T.C.
DÜZCE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EVRIŞİMSEL SİNİR AĞLARI KULLANARAK PARMAK UCU
GÖRÜNTÜLERİNDEN CİNSİYET TAHMİNLEMESİ

Kerem SIRMA tarafından hazırlanan tez çalışması aşağıdaki jüri tarafından Düzce Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Pakize ERDOĞMUŞ

Düzce Üniversitesi

Jüri Üyeleri

Prof. Dr. Pakize ERDOĞMUŞ

Düzce Üniversitesi

Doç. Dr. Devrim AKGÜN
Sakarya

Üniversitesi

Dr. Öğr. Üyesi Abdullah Talha KABAKUŞ
Düzce Üniversitesi

Tez Savunma Tarihi: 14/01/2021

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.



14 Ocak 2021

Kerem SIRMA

TEŐEKKÖR

Yüksek lisans öğrenimimde ve bu tezin hazırlanmasında gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Prof. Dr. Pakize ERDOĞMUŐ'a en içten dileklerle teşekkür ederim.

Bu çalışma boyunca yardımlarını ve desteklerini esirgemeyen sevgili aileme ve çalışma arkadaşlarıma sonsuz teşekkürlerimi sunarım.

14 Ocak 2021

Kerem SIRMA

İÇİNDEKİLER

Sayfa No

ŞEKİL LİSTESİ	VI
ÇİZELGE LİSTESİ	VII
KISALTMALAR.....	VIII
SİMGELER	IX
ÖZET	X
ABSTRACT	XI
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ	4
3. MATERYAL VE YÖNTEM.....	9
3.1. PROBLEM TANIMI	9
3.2. EVRİŞİMSEL SİNİR AĞLARI (CNN)	9
3.2.1. Evrişim (Konvolüsyon) Katmanı	10
3.2.2. Ortaklama Katmanı.....	11
3.2.3. Düzleştirme Katmanı	11
3.2.4. Düzeltilmiş lineer katman (ReLU).....	12
3.2.5. Tam bağlı katman	12
3.2.6. Dropout katmanı	13
3.2.7. Sınıflandırma katmanı.....	13
3.3. TRANSFER ÖĞRENME	13
3.4. VERİ ARTIRMA	14
3.5. HİPER PARAMETRELER.....	14
3.5.1. Mini-Batch Boyutu.....	15
3.5.2. Eğitim Tur Sayısı.....	15
3.5.3. Öğrenme Oranı.....	15
3.5.4. Optimizasyon Yöntemi	15
3.5.4.1. Momentumlu stokastik eğim düşüm (Stochastic Gradient Descent with Momentum).....	16
3.5.4.2. Adaptif Moment Tahmin (Derived from Adaptive Moment Estimation).....	16
3.5.4.3. Kare Ortalamalarının Karekökü Yayılımı (Root Mean Square Propagation).....	17
3.6. ÇALIŞMADA KULLANILAN CNN YAPILARI.....	17
3.6.1. Temel Model	18
3.6.2. Veri Artırımı Uygulanmış Model	22
3.6.3. Transfer Öğrenme Uygulanmış Model	22
3.6.4. Transfer Öğrenme ve Veri Artırımı Uygulanmış Model.....	25
3.7. K KATLAMALI ÇAPRAZ DOĞRULAMA	25
4. BULGULAR VE TARTIŞMA	27
5. SONUÇLAR VE ÖNERİLER	34
6. KAYNAKLAR.....	36
ÖZGEÇMİŞ	43

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 1.1. Veri setinden görüntü	2
Şekil 3.1. CNN katmanları.....	10
Şekil 3.2. Evrişim işlemi.....	10
Şekil 3.3. Ortaklama işlemi.....	11
Şekil 3.4. Flattening işlemi	12
Şekil 3.5. Tam Bağlı katman	13
Şekil 3.6. Bir ESA ağına Dropout katmanı uygulanması	13
Şekil 3.7. Genel akış diyagramı.	18
Şekil 3.8. Cinsiyet tahmini için önerilen CNN modeli	21
Şekil 3.9. Veri artırımı ile çoğaltılmış örnek görüntüler.....	22
Şekil 3.10. AlexNet ile transfer öğrenme uygulaması.	25
Şekil 4.1. N katlamalı çapraz doğrulama işlemi	26
Şekil 4.2. K=5 için çapraz doğrulama işlemi.....	26
Şekil 4.3. Önerilen modelin doğruluğu ve iterasyon sayısı	27
Şekil 4.4. Uygulanan anketten soru örneği	28
Şekil 4.5. Katılımcıların tahmin başarısı	33
Şekil 4.6. Parmak ucu görüntüsünden cinsiyet tahmini yapabilen Matlab uygulaması .	33

ÇİZELGE LİSTESİ

	<u>Sayfa No</u>
Çizelge 3.1. Matlab’da AlexNet modeli	23
Çizelge 4.1. Değiştirilen parametreler ve değerleri	27
Çizelge 4.2. Veri, katman ve hiper parametre değerlerinin sonuçlara etkisi	29
Çizelge 4.3. Siyah beyaz renk dönüşümün sonuçlara etkisi	30
Çizelge 4.4. 10 kat çapraz doğrulama	31
Çizelge 4.5. 5 kat çapraz doğrulama	31
Çizelge 4.6. 4 kat çapraz doğrulama	31
Çizelge 4.7. 3 kat çapraz doğrulama	32
Çizelge 4.8. 2 kat çapraz doğrulama	32

KISALTMALAR

ADAM	Derived from adaptive moment estimation batch normalization
BN	Batch normalization
CNN	Convolutional neural network
ESA	Evriřimsel sinir aęları
FC	Fully connected
GPU	Grafik iřlemci birimi
ReLU	Rectified linear units
ResNet	Residual network
RMSprop	Stochastic gradient descent with momentum
SGDM	Root mean square propagation
SVM	Support vector machine
T.M	Temel model
T.Ö.U. M	Transfer öęrenme uygulanmıř model
T.Ö.V.U.M	Transfer öęrenme ve veri artırımı uygulanmıř model
V.A.U.M	Veri artırımı uygulanmıř model
YSA	Yapay sinir aęı

SİMGELER

°
%

Derece
Yüzde



ÖZET

EVRIŞİMSEL SİNİR AĞLARI KULLANARAK PARMAK UCU GÖRÜNTÜLERİNDEN CİNSİYET TAHMİNLENMESİ

Kerem Sırma

Düzce Üniversitesi

Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Pakize Erdoğan

Ocak 2021, 42 sayfa

Son yıllarda günlük hayatımıza birçok yenilik getiren ve araştırmacılara yeni çalışma alanları oluşturan yapay zekâ teknolojisinin önemi gün geçtikçe artmaktadır. Cinsiyet sınıflandırma konusu da yapay zekâ alanının önemli bir araştırma konusudur. Yüz, vücut hatta parmak izi görüntülerinden cinsiyet tahmini üzerine çalışmalar yapılmıştır. Ayrıca günümüzde biyometrik tanıma sistemleri insanların parmak izlerini, yüzünü, irisini, avuç içi izlerini, imzasını, DNA ve retinasını belirleyebilecek seviyelere çıkmıştır. Çalışmada yeni bir biyometrik sistem oluşturulmasına olanak sağlayacak bir yöntem önerilmiştir. Bu çalışmada parmak ucu görüntülerinden cinsiyet sınıflandırma üzerine çeşitli modeller eğitilip, denemeler yapılmıştır. Çalışmada hazır bir veri seti kullanılmayıp 200'den fazla kişiden parmak görüntüsü toplanmıştır. Toplanan görüntülere döndürme, kesme ve arka plan azaltma işlemleri uygulanıp eğitim için hazır hale getirilmiştir. Yapılan çalışmada 4 farklı ağ modeli oluşturulmuştur. Bu modellerde veri artırma işlemleri ve transfer öğrenme kullanılmıştır. Kısıtlı bir alanda çalışma yapmak, her görüntünün kalitesinin ve açılarının farklı olmasına rağmen oluşturduğumuz model yüksek başarımlı sonuçlara ulaşmıştır. Bu çalışmada önerilen model %86,39 başarımlı orana sahiptir.

Anahtar sözcükler: Cinsiyet tahmini, Derin öğrenme, Parmak ucu.

ABSTRACT

GENDER PREDICTION FROM FINGERTIP IMAGES USING CONVOLUTIONAL NEURAL NETWORKS

Kerem SIRMA

Düzce University

Graduate School of Natural and Applied Sciences, Department of Computer
Engineering

Master's Thesis

Supervisor: Prof. Dr. Pakize Erdoğan

January 2021, 42 pages

Bringing several innovations to our daily life, the importance of artificial intelligence technology has been increasing day by day and has created new fields for researchers. Gender classification is also an important research topic in the field of artificial intelligence. Studies on gender prediction from face, body and even fingerprint images have been done. In addition, today, biometric recognition systems have reached levels that can determine people's fingerprints, face, iris, palm prints, signature, DNA and retina. In this study, various models were trained and tested on gender classification from fingertip images. In the, a ready data set was not used and finger images were collected from more than 200 people. Rotation, cutting and background reduction are applied to the collected images and made ready for the training. 4 different network models were set in the fieldwork. Data augmentation and transfer learning were used in these models. Working in a limited area, the model we created has achieved high performance results, for all that the quality and angles of each image are different. The model proposed in this scientific study has an achievement drive of 86.39%.

Keywords: Deep learning, Fingertip, Gender prediction.

1. GİRİŞ

Makine öğrenmesinin alt dalı olan derin öğrenme uygulamalarının kapsam alanlarının giderek artması, büyük veri oluşumundaki yükselişin doğal bir sonucudur. Konuşma tanıma, nesne tanıma, duygu analizi ve görüntü sınıflandırma derin öğrenmenin çalışma alanlarından bazılarıdır. Araştırmacılar oldukça geniş bir araştırma alanı olan yapay öğrenme tekniklerini geliştirerek insan gibi karar verebilen bilgisayar modelleri oluşturmaya çalışmaktadırlar [1], [2].

Telefonlardaki uygulamalar, televizyonlar, reklam panoları veya internette karşımıza çıkan reklamlar, fen bilimleri ve tıp alanındaki gelişmeler, bilgisayar oyunları derin öğrenmenin çözüm bulmaya çalıştığı problemlerden bir kaçıdır.

Bu tezde insan parmaklarının uç görüntülerinden cinsiyet sınıflandırmada başarı oranını artırmak, hata payını azaltmak hedeflenmiştir. Çalışmada evrimsel sinir ağlarından birkaç farklı metot kullanılmış ve sonuçlar birbirleri ile karşılaştırılmıştır. En iyi sonuca ulaşabilmek için bazı hiper parametreler değiştirilerek testler tekrarlanmıştır.

Veriler toplanırken katılımcılara çalışmanın amacı anlatılmış ve kişisel veriler korunmuştur. Verilerin araştırmacılar yararına Kaggle gibi ortamlara yükleneceği ve kişisel verilerin korunması için kimlik bilgilerinin paylaşılmayacağı açıkça belirtilmiştir. Veriler yazara yalnızca e-posta yoluyla ve sıkıştırılmış bir biçimde gönderildi. Ayrıca Kaggle ortamı dışında herhangi bir sunucuya yüklenmemiş ve üçüncü şahıslarla herhangi bir bilgi paylaşılmamıştır.

Literatürde genelde bu tür cinsiyet sınıflandırma çalışmalarında yüz görüntüleri içeren Adience veri setinin kullanıldığı görülmüştür [3], [4]. Çalışmada, veri setini oluşturmak için iki elin parmaklarının görüntüleri toplandı. Bu süreçte 200'den fazla kişiye ulaşıp 2110 parmak görüntüsü elde edildi. Verilere kesme, döndürme ve arka plan azaltma işlemleri uygulandı. Veriler, farklı çözünürlükte kameraya sahip akıllı telefonlar ile farklı poz ve aydınlatma şartları altında elde edildi. Bu nedenlerden dolayı görüntü kalitesi açısından büyük değişimler mevcuttur. Tamamen bulanık ve tepeden çekilmeyen görüntüler veri setinden çıkarılmıştır. Cinsiyet sınıflandırma için 2 sınıf (kadın / erkek) vardır.



Şekil 1.1. Veri setinden görüntü.

Çalışmalarımız Matlab r2019b ile yapıp sonuçları gerçek hayatla karşılaştırmak için 100 kişiye Google Anket uygulaması ile 100 soruluk anket yapılmıştır. Derin Öğrenmenin klasik yapay sinir ağlarından üç temel farkı vardır: 1) Ara katman sayısı çok fazla olabilir. Örneğin GoogleNet'in 22 katmanı mevcuttur [5]. 2) Eğitim kümesindeki görüntü ve kategori sayısı oldukça yüksek olabilir. Örnek olarak Yahoo Flickr verilebilir. 100 milyon görüntü ve 2000 sınıfa sahiptir [6]. 3) Sistem girişi vektör yerine görüntü olabilir. Bunun yanında Boltzman makineleri, autoencoders ve Evrimsel Sinir Ağları (ESA), derin öğrenme alanında kullanılan mimariler olarak örnek verilebilir. Kullanım kolaylığı, yüksek tahmin kabiliyeti ve ekran kartı destekli paralel çalışma özellikleri nedeniyle ESA, görüntü sınıflandırmada güncelliğini koruyan yöntemler içerisinde yer almaktadır [7], [8], [9]. Ayrıca ESA mimarisi ilk ImageNet adlı büyük bir eğitim setinde kullanılmıştır. Problem çözümlerinde ESA'yı tercih eden araştırmacıların en çok karşılaştığı sorunlardan biri probleme özgü veri setinin hazırlanmasıdır. ESA'nın yüksek katman sayısı ile probleme göre yeterli görüntüleri içeren bir eğitim setinin araştırmacılar tarafından oluşturulması gerekmektedir. Örneğin ImageNet veri seti, bir milyon görüntünün 1000 sınıftan biriyle etiketlenmesi sonucu oluşmuştur. Büyük çalışmalar sonucu hazırlanan bu set kullanılarak eğitilen bir Convolutional Neural Network (CNN) yüksek doğrulukta tahmin yapılabilmektedir.

Ancak bizim çalışmamız gibi araştırmalarda yeterli sayıda veri bulmak oldukça güçtür veya bulunamamaktadır. Yeterli verinin bulunamaması durumunda yüksek başarımlarına sahip ESA'yı nasıl kullanacağız sorusu karşımıza çıkmaktadır. Bu sorunun çözümü için “transfer öğrenme” ya da diğer adıyla “bilgi transferi” yaklaşımı kullanılmaktadır. Bilgi transferi ImageNet veya eğitim başarısı ispatlanmış bir veri kümesi ile eğitilmiş bir ESA ağından bilgi transferinin gerçekleştirilmesidir. Bu çalışmada AlexNet ile transfer öğrenme denenmiştir. Bu yöntem, derin öğrenme yöntemlerinin geliştirilmesi ile beraber önemli bir araştırma konusu durumuna gelmiştir. Transfer öğrenme, klasik Yapay Sinir Ağı (YSA) modellerinde olduğu gibi insan öğrenme modeline benzemektedir. İnsanlar da öğrenirken daha önce karşılaşmadıkları bir problemi çözmek için önceden tecrübe ettiği problemlerin çözümünden faydalanırlar [10], [11]. Bu çalışmada transfer öğrenme yaklaşımı ve veri artırma yöntemleri de incelenmiştir. Bu yaklaşımların performans ve doğruluk şartları sürekli değiştirilerek karşılaştırılmış ve elde edilen sonuçlar tablolarla sunulmuştur.

Bu amaçla, tezin ikinci bölümünde ESA yaklaşımı üzerine derinlemesine bir literatür taramasına yer verilirken üçüncü bölümde, ESA, transfer öğrenme, hiper parametreler ve veri artırma yaklaşımı ifade edilmektedir. Oluşturulan 4 model de yine bu kısımda anlatılmıştır. Dördüncü bölümde, hiper parametrelerin, veri seti boyutunun ve kullanılan yöntemlerin ESA üzerindeki etkisi ve çıkarılan bulgular açıklanmaktadır. Son bölümde ise yapılan uygulama neticesinde elde edilen genel sonuçlar paylaşılmaktadır.

2. LİTERATÜR ÖZETLERİ

Yapılan bu çalışmaya benzer olarak, Rodríguez ve ark. [12] yüz görüntüleri kullanarak yaş ve cinsiyet tahmini yapabilen bir Convolutional Neural Network (CNN) tasarlamış ve Audience veri seti kullandıkları bu sistemde daha önce yapılan birçok modelin sonuçlarını da karşılaştırmışlardır. %92 doğruluk oranıyla cinsiyet tahmini yapmışlardır. Illouz ve ark. [13] el yazısından cinsiyet tahmin edebilen bir CNN tasarlamıştır. 405 katılımcı ile toplam 810 İngilizce ve İbranice yazılmış el yazısı kullanmışlardır. Minimum %71.05 ve maksimum 78.95 doğruluk oranına erişmişlerdir. Baek ve ark. [14] çokça yapılan yüz görüntülerinden cinsiyet tahmin etme çalışmalarından farklı olarak vücut görüntüsünün tamamını kullanarak cinsiyet tahmini yapmayı amaçlamışlardır. Gölge, kıyafet ve aksesuar gibi etmenler performansı etkileyeceği için kızılötesi kameralar kullanıp sadece vücut şekline odaklanmışlardır. Liu ve ark. [15] insan yürüyüşünden cinsiyet tahmini yapmayı amaçlamış ve Softmax yerine Support Vector Machine (SVM) kullanmışlardır. VGG16 ile %87,10 olan doğruluk oranını SVM kullanarak %89,62'ye çıkarmışlardır.

Nistor ve ark. [16] CNN kullanarak yüz görüntülerinden cinsiyet sınıflandırıcı yapmış ve bu sistemi birçok veri seti ile denemişlerdir. Birden fazla veri seti birleştirerek yaklaşık 70.000 yüz görüntüsü ile %98,2 başarı oranına sahip olmalarına rağmen internetten kendi araştırmalarıyla topladıkları görüntülerle oluşturdukları veri seti ile %84 başarı elde etmişlerdir. Gauswami ve ark. [17] Audience veri seti ile bir CNN tasarlayıp Raspberry pi ile kullanmışlar. Çalışmada veri artırma kullanılmış ve 256×256'lık görseller rastgele kesilerek 227×227 ye indirilmiştir. Raspberry Pi 'ye bir kamera modülü bağlanmış ve yüz görüntülerinden cinsiyet tahmini yapılmıştır. Akbulut ve ark. [18] derin öğrenme ile yüz imgelerinden cinsiyet tanıma gerçekleştirmişlerdir. Derin öğrenme yöntemi olarak Yerel Alıcı Alanlar-Aşırı öğrenme Makinesi (YAA-AÖM) ile Evrimsel Sinir Ağları (ESA) kullanılmışlardır. Deneyler, yaş ve cinsiyet tanıma için oluşturulan yüz görüntüleri içeren bir veri setinde gerçekleştirilmiştir. YAA-AÖM ile %80 ve ESA ile %87,13 başarı oranına ulaşılmıştır. Viedma ve ark. [19] VggNet ve ResNet ile karşılaştırarak iris görüntülerinden cinsiyet tahmin edebilen bir CNN tasarlamışlardır. GFI-UND veri seti kullanarak ResNet ve VggNet ile ortalama %75 başarı oranlarına ulaşmışlar. Fakat kendi tasarladıkları ağ ile daha az katman kullanarak %85 başarı oranı elde etmişlerdir. Hosseini ve ark. [20] derin öğrenmede

ağı giderek derinleştirmenin genelde iyi sonuç verdiğini fakat bunun her zaman doğruluğu artırmadığına değinmişlerdir. Audience veri setini kullanmışlar ve ağa ek olarak gabor filtresi uygulamışlardır. Bir Gabor filtresi, harmonik bir fonksiyon ile Gaussian fonksiyonunun çarpımından oluşan lineer bir filtredir. Gabor Filtresi ile cinsiyet tahmininde %2, yaş tahmininde %7 artış sağlanmıştır. Lee ve ark. [21] Audience veri seti kullanarak mobil cihazlar için daha hafif ve kullanılabilir bir ağ tasarlamışlardır. 256×256 resimleri 227×227 olacak şekilde kırpıp yaş ve cinsiyet tahmini yapmışlardır. Cinsiyet tahmininde maksimum %85,16 başarı oranı elde etmişlerdir. Kabasakal ve ark. [22] sadece iki katmandan oluşan bir sistem tasarlamıştır; (i) yüz algılama ve (ii) cinsiyet tespiti. Sistemin ilk aşamadaki hedefi, sayısal imgelerde ön cepheden insan yüzlerini algılayabilmektir. Bu işlemde doğrusal sınıflandırıcı ile Yönlü Gradyanlar Histogramı (HOG) öznelik belirleyici olarak kullanılmıştır. İkinci aşamada, cinsiyet tespiti için iki farklı sınıflandırıcı eğitilmiştir. Birinci sınıflandırıcı için Destek Vektör Makineleri (SVM), ikinci sınıflandırıcı için Derin Öğrenme olarak da bilinen Evrişimsel Sinir Ağları (ESA) sınıflandırıcısı eğitilmiştir. CNN sınıflandırıcısı için GoogleNet derin sinir ağı mimarisi kullanılmış ve en uygun şekle getirme işlemi parametrelere bağlı olarak yapılmıştır. Her iki sınıflandırıcının eğitimi için LFW, IMDB ve WIKI veri setleri kullanılmıştır. Yapılan çalışmaların sonuçlarına göre, CNN tabanlı sınıflandırıcı SVM tabanlı sınıflandırıcıya göre daha üstün başarı elde etmiştir. Antipov ve ark. [23] 50×150 boyutunda yaya görüntüleri içeren PETA veri seti kullanarak cinsiyet tahmin eden bir CNN tasarlamış ve yaptıkları en iyi model ile %79 başarı oranına ulaşmışlardır. Bilinen bir ağ olan AlexNet ile kıyaslamışlardır. Morera ve ark. [24] İngilizce el yazıları içeren IAM veri seti ile Arapça el yazıları içeren KHATT veri seti kullanarak bir CNN tasarlamışlar ve cinsiyet tahmin etme işleminde ortalama %68,90 başarı elde etmişlerdir. Ito ve ark. [25] yüz görüntülerinden yaş ve cinsiyet tahmini için IMDB veri seti kullanarak bir model oluşturmuş ve daha önce eğitilmiş ağlar ile sonuçları karşılaştırmışlar. Sonuç olarak %93,57 başarı elde etmişlerdir. Arora ve ark. [26] boyutları 640×480 olan ve 2500 adet yüz görüntüsü barındıran CASIA veri setini kullanılmışlardır. Konvolüsyon ve Max Pooling katmanları kullanılarak 50 epoch ile %98,5 başarı elde edilmiştir. Python ve TensorFlow kullanılan model katman ve filtre sayısı bu çalışmadaki yapıyla benzerdir. Afifi [27] 11.000 el görüntüsüyle cinsiyet tahmini yapabilen bir model geliştirmiştir. Birçok veri setini birleştirerek bu sayıya ulaşmıştır. 30 epoch ve 0,0001 öğrenme oranı ile avuç içinde %87, elin üst görüntüsünde ise %91 başarı oranına ulaşmıştır. Toplam

görüntü sayısı benzersiz olmamakla birlikte bir elin çeşitli açılardan çok sayıda görüntüsü mevcuttur. Bu tez için kullanılan veri setinde ise her parmak benzersizdir. Barbosa ve ark. [28] tırnak görüntüleri kullanılarak geçici bir biyometrik sistem tasarlamışlardır. Derin öğrenme algoritması kullanılmamış ve yapılan testlerde tırnağın şekline bağlı olarak 1 hafta sonra tanımanın başarılı, 2 ay sonra ise başarısız olduğu görülmüştür. Bu tezde oluşturulan modelde, kullanılan veri sayısına göre oldukça az veriyle çalışılmış. Yaptığımız çalışma ile bu çalışma yeni bir biyometrik tanıma sisteminin öncüsü sayılabilir. Karakaş [29] bu alanda yapılan çalışmaların çoğunda olduğu gibi Adience veri seti kullanmış ve oy çokluğu yöntemi ile test edilen yöntemler füzyon edilip bu füzyon çıktısı gerçek değerlerle karşılaştırılmıştır. Cinsiyet sınıflandırmada %92,29, yaş grubu sınıflandırmada %60,26 başarı elde edilmiştir. Gündüz [30] öncelikli olarak literatürde yaş ve cinsiyet tahminini derin öğrenme kullanarak gerçekleştiren metotlar uygulanmıştır. Uygulamada kullanılan veri seti kadın ve erkek fotoğraflarından oluşturulmuştur. Her fotoğraf kişi cinsiyetine ve yaşına göre etiketlenmiştir. Bu veri seti Wikipedia görüntülerinden derlenmiştir, 3170 eğitim verisi ve 318 test verisi içermektedir. Oluşturulan üç farklı model ile sonuçları karşılaştırılmıştır. %72,20 başarı elde edilmiştir. Cui ve ark. [31] genel olarak insan cinsiyeti tahmin etmenin aksine yengeç görüntülerinden cinsiyet tahmin edebilen bir CNN tasarlamışlardır. VggNet ile %96,69, kendi geliştirdikleri model ile %98,90 başarı elde etmişlerdir. Liu ve ark. [32] normal yüz görüntülerinden cinsiyet analiz eden uygulamaların yanı sıra ayrı ayrı yüz bileşenlerinden cinsiyet tahmini yapabilen bir model tasarlamışlar ve parçalar (ağız, burun vb.) şeklinde olan yüz görüntülerinde daha yüksek doğruluk oranları (%89,60) elde edilmiştir. Kuehlkamp ve ark. [33] 600 görüntüye sahip bir veri setinin kullanıldığı çalışmalarında göz makyajının cinsiyet tahmininde bir etkisinin olup olmadığını araştırmışlardır. Çalışma yapılırken hem tam göz görüntüsü hem de sadece iris görüntüsü kullanılmıştır. Aynı şekilde bu görüntülerin makyajlı ve makyajsız halleri kullanılmıştır. Çalışmada kozmetik ürünlerinin kullanımının analiz edilen her iki versiyon için de doğruluğu düşürdüğünü ispatlamışlardır. Oluşturulan model %66 başarı oranına sahiptir. Geng ve ark. [34] kullanıcıların attıkları tweet ve profil resimlerine göre cinsiyet tahmini yapabilen bir model tasarlamışlardır. Çalışmada yazı, görüntü ve her ikisini kullanan çalışmalara atıflarda bulunulmuş. Bir Tweeter API'si kullanarak toplamda 29.410.050 tweet elde edilmiştir. Ayrıca rastgele 1000 kullanıcının profil resmi çekilmiş ve çekilen resimler önce 256×256 olarak tekrar boyutlandırılmıştır. %86,54 oranında başarı elde

edilmiştir.

Antipov ve ark. [35] bir CNN tasarladıktan sonra ağı konvolüsyon katmanlarındaki filtre sayıları ve tam bağlı katmanın boyutunu azaltmışlardır. Bu katman ve filtre azaltmaları hem hız hem de hafıza kazanımı sağlamıştır. Buna bağlı olarak başarı oranında göz ardı edilebilecek düşüş yaşanmıştır. Juefei-Xu ve ark. [36] geleneksel yöntemlere göre düşük çözünürlükte ve yaklaşık 400.000 yüz görüntüsünden oluşan PCSO mugshot veri seti kullanılmıştır. Resimleri tamamen kullanmak yerine bulanıklaştırıp kullanmışlardır. Bulanık olduğunda, düşük frekanslı bilgilerin korunduğunu yani görüntünün içeriği hala tanınabilir olduğunu belirlemişlerdir. Perioküler bölgenin dışında yapılan bulanıklaşma, perioküler bölgedeki yüksek frekans detayları daha iyi kullanmalarını sağlamıştır.

Liew ve ark. [37] çalışmalarında 32×32 piksel boyutunda SUMS ve AT&T veri setleri kullanmışlardır. %98,75 ve %99,38 başarı elde edilmiştir. 20 epoch ile görüntü boyutlarının da küçük olmasından dolayı oldukça hızlı ve performanslı bir ağ olmasını sağlamış. Ayrıca LeNet-5 CNN ile kıyaslama yapılmıştır. Perlin ve ark. [38] Lenet-5 modelini değiştirerek sağ ve sol göz görüntülerinden cinsiyet belirleyebilen bir model geliştirmişlerdir. Çalışmalarında veri artırma kullanarak 10 derece döndürme, en ve boy da 0.2 kaydırma ve görüntülerde %15 yakınlaştırma yapıp ND-GFI veri setini kullanmışlardır. 0.00001, öğrenme oranı, 300 epochs ve 256 mini yığın boyutuyla %87,26. başarı elde etmişlerdir. Antipov ve ark. [39] çalışmalarıyla ChaLearn Apparent Age Estimation Challenge 2016 da galibiyet almışlardır. Yüz görüntüleri içeren IMDB-Wiki_cleaned veri seti kullanılmış ve veri setinden 250.000 görüntü çıkarılmıştır. Bunun yanında farklı veri setleri de kullanılmış ve çeşitli ağ modelleriyle karşılaştırma yapmışlardır. Yaptıkları çalışmada %99,4 başarı oranı elde etmişlerdir.

Rattani ve ark. [40] göz bölgesinden yaş tahmini yaptıkları çalışmalarında 6 katmanlı bir CNN tasarlanmıştır. Göz bölgesi resimleri griye çevrilip 32×92 'ye yeniden boyutlandırmışlardır. Mini yığın boyutu: 64 öğrenme oranı: 0.001 parametreleriyle Adience Veri seti kullanıp %80,96 başarı oranı elde etmişlerdir. Levi ve ark. [3] yaş ve cinsiyet tahmini yaptıkları çalışmalarında Adience veri seti kullanmışlardır. Resimlerde herhangi bir boyutlandırma işlemi veya grileştirme yapılmamıştır. 3 Konvolüsyon katmanı ve 2 tam bağlı katman kullanarak tasarladıkları model ile %86,8 başarı elde etmişlerdir. Doukhan ve ark. [41] Fransızca kadın ve erkek konuşmalarından cinsiyet tahmini yaptıkları çalışmalarında, veri seti olarak INA's Speaker Dictionary

kullanmışlardır. Bu veri setinde 1780 erkek konuşması (94 saat) ve 494 kadın konuşması (27 saat) mevcuttur. Çalışmanın sonunda %97,42 doğruluk oranı elde edilmiştir. Bu çalışmaya benzer olarak farklı bir veri seti kullanarak yüz görüntüleri ile konuşmayı birleştirerek bir CNN modeli tasarlayan Qawaqneh ve ark. [42] %56.06 başarımla elde etmişlerdir.

Choubisa ve ark. [43] Vücut görüntülerinden cinsiyet tahmini yaptıkları çalışmalarında insanların önden görüntüsü değil, sağ ve sol taraftan çekilmiş görüntülerini analiz ederek bir CNN modeli tasarlamışlardır. %94,10 doğruluk oranına ulaşmışlardır. Liu ve ark. [44] farklı bir ağ tasarlamayıp Adience veri seti kullanarak yüz görüntülerinden yaş ve cinsiyet tahmini yapabilmek için GoogleNet tabanlı WebCam bağlı bir sistem kurarak gerçek zamanlı tahminde bulunmuşlardır. Janahiraman ve ark. [45] Asyalıların yüz imgelerinden cinsiyet tanıyan bir araştırma yapmışlardır. Özel bir ağ tasarlamamışlardır. Var olan 3 ağı (VGG-16, ResNet-50 ve MobileNet) denemişlerdir. 1000 görüntü içeren veri setleriyle yaptıkları çalışmalarında VGG-16 %88 oranla en yüksek sonucu ve MobilNet ise %49 ile en düşük sonucu vermiştir. Smith ve ark. [46] VGG19 ve VGGFace modellerini kullanarak transfer öğrenme çalışması yapmış ve cinsiyet tanımada %98,7 sonuç alınmıştır. Yaptıkları çalışmada hiper parametreleri mini yığın boyutu: 50, epoch: 60 olarak değiştirip, görüntüleri 200×240 olarak yeniden boyutlandırmışlardır. Yaman ve ark. [47] kulak görüntülerinden yaş ve cinsiyet tahmini yaptıkları çalışmalarında bir ağ geliştirmemiş ve var olan ağlara göre giriş görüntülerini yeniden boyutlandırıp denemeler yapmışlardır. En yüksek sonucu %94 ile GoogleNet vermiştir. Ceyhan ve ark. [48] yaptıkları çalışma ile parmak izlerinden cinsiyetlerin tahmin edilmesi için Yapay Sinir Ağları (YSA) modeli tabanlı yeni bir metot önermektedir. Modelleme işlemleri, parmak izi elde etme, elde edilen parmak izi görüntülerinin farklı boyutlarda analizi, tepe noktalarının hesaplanması, bireylerin parmak izi ortalama tepe değerlerinin bulunması ile yapılmıştır. Daha sonra bu öznetelikler model içerisinde birleştirilmiştir. Çalışmada model yapısının hazırlanması, ayarlanması ve son olarak modelin test edilmesi konu alınmıştır. Önerilen modelin sonuçları %72 başarımla oranına sahiptir.

3. MATERYAL VE YÖNTEM

3.1. PROBLEM TANIMI

Bu çalışmada daha önce yapılmamış ve zor bir iş olan parmak ucu görüntülerinden cinsiyet ayrımı yapılabilir mi sorusuna cevap aranmıştır. Özellikle yüz görüntülerinden cinsiyet tahmininde çok iyi sonuçlar veren ESA yapılarının ne kadar başarılı olabileceği üzerine yöntemler geliştirilip, testler yapılarak problem çözülmeye çalışılmıştır.

Buradaki ana zorluklardan biri, birçok engel ve gürültünün yanlış sonuçlara yol açabilecek olmasıdır. Parmak görüntülerinin doğru ışık koşullarında ve kaliteli bir kamera ile çekilmesi özelliklerin doğru bir şekilde çıkarılmasını ve aynı oranda tahmin doğruluğunun artmasını sağlayacaktır. Ancak çalışmada 200'den fazla insanın farklı parmak görüntülerinin kullanıldığı ve hepsinin farklı açılarda, farklı kalitede kameraya sahip cep telefonlarından çekildiği için başarı oranında yüksek azalmalara sebep verecektir. Bu sorunların önüne geçmek için döndürme, kırpma ve arka plan azaltma işlemleri uygulayarak kaybı en aza indirmeye çalıştık. Bu işlemler haricinde doğal yaşama ve gerçekliğe yakın sonuçlar çıkması için herhangi bir filtreleme, bulanıklaştırma gibi işlemler uygulanmamıştır.

Cinsiyet sınıflandırma için 2110 parmak görüntüsü ile çalışma yapılmıştır.

3.2. EVRİŞİMSEL SİNİR AĞLARI(CNN)


CNN, görüntüleri ayırt etmek için bir eli el yapan ya da bir uçağı uçak haline getiren benzersiz özellikleri kullanır. Aslında bu süreç beynimizde de aynı bu şekilde biz farkında olmadan olmaktadır. Örneğin bir el resmine baktığımızda parmak, tırnak gibi özellikleri birbirinden ayırarak eli tanımlayabiliriz. CNN de aynı şekilde davranır ancak daha önce eğriler ve kenarlar gibi alt düzey özellikleri tespit eder ve daha soyut katmanlara kadar bunları oluşturur. Bu işlevselliği oluşturmak için görüntüyü çeşitli katmanlarda işleyerek bir süreçten geçirir. Bunlar Convolutional (Evrışimsel), Pooling (Downsampling) (Ortaklama), Flattening (Düzeltilmiş), ReLU, Fully-Connected (Tam Bağlı), Dropout ve Classification (Sınıflandırma) katmanlarıdır.



Şekil 3.1. CNN katmanları.

3.2.1. Evrişim (Konvolüsyon) Katmanı

Evrişim katmanı CNN'nin temel taşıdır. Resmin özelliklerini algılar. Ayrıca görüntüde yüksek ve düşük seviyedeki özellikleri çıkarmak için resme birtakım filtreler uygular. Bu filtre kenarları algılayabilir ve genellikle çok boyutludur. Örneğin $(3 \times 3 \times 1)$ boyutlarındaki bir görüntü de 3 matrisin yükseklik ve genişliğini, 1 ise matrisin derinliğini temsil eder.



Şekil 3.2. Evrişim işlemi.


İlk olarak, filtre görüntünün sol üst köşesindeki ilk piksel değerine konumlandırılır. Burada, iki matris arasında (görüntü ve filtre) indisler birbirleriyle çarpılır ve tüm sonuçlar toplanır, daha sonra sonucu çıkış matrisine aktarılır. İkinci olarak, bu filtreyi sağa doğru 1 basamak hareket ettirip aynı işlemi tekrar eder. İlk satır bittikten sonra ikinci satıra geçilir ve işlemler tekrarlanır. Tüm satır işlemleri bittikten sonra çıkış matrisi oluşur. Çıkış matrisinin 3×3 olmasının sebebi görüntüye uygulanan filtrenin yatayda ve dikeyde 3 kez hareket etmesinden kaynaklanır. Birden fazla özelliği tespit

etmek için daha fazla sayıda filtre kullanılır. Evrişim katmanında kaydırma işlemi (Stride) kullanılabilir. Stride, evrişim işlemi için ağırlık matrisi olan filtreyi görüntü üzerinde istenilen piksellik adımlarla kaydırılacağını bilgisini verir. Bu sebeple doğrudan çıkış boyutunu etkileyen önemli bir parametredir. Bu çalışmada stride 2 olarak belirlenmiştir.

3.2.2. Ortaklama Katmanı

Ortaklama katmanı, ESA katmanları arasına sıklıkla eklenmektedir. Kullanılma sebebi ise, gösterimin kayma boyutunu, parametreleri ve hesaplama sayısını azaltmaktır. Bu nedenle ağıdaki uyumsuzluk kontrol edilir. Birçok çeşidi vardır, fakat en popülerleri bizimde çalışmamızda kullandığımız maksimum havuzlama katmanıdır.

2×2 filtrenin 4×4 görüntü üzerinde uygulandığı durum şekil 3.3 de gösterilmiştir. Filtre, kapsadığı alandaki en büyük sayıyı alır. Bunun sonucunda, sinir ağının doğru karar vermesi için yeterli bilgiyi içeren daha küçük çıktılar elde edilmiş olur.




Şekil 3.3. Ortaklama işlemi.

Bununla birlikte birçok kişi bu katmanı kullanmayı tercih etmez. Bunun yerine Convolutional katmanında daha büyük Stride (Filtreyi kaydırma işlemi) tercih edilir. Ayrıca Variational Autoencoders ve Generative Adversarial Networks gibi modellerde ortaklama katmanını tamamen çıkarılır [49], [50].

3.2.3. Düzleştirme Katmanı

Son katman olan tam bağlı katmanın girişindeki verileri hazırlar. Genel olarak, YSA'lar, giriş verilerini tek boyutlu (linear) bir diziden almaktadır. Bu veriler ise Evrişim ve

Ortaklama katmanından gelen matrislerin tek boyutlu bir diziye çevrilmiş halidir.



Şekil 3.4. Flattening işlemi.


3.2.4. Düzeltilmiş lineer katman (ReLU)

Bu kısım sıfırdan küçük olan herhangi bir giriş değerinin sıfıra eşitlendiği bir katmandır. Aşağıdaki fonksiyon şeklinde tanımlanabilir [51].

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.1)$$

3.2.5. Tam bağlı katman


Bu katman ESA'nın son ve en önemli katmanıdır. Çıkış boyutunun belirlendiği katmandır. Örneğin bu çalışma da kadın ve erkek sınıflandırılması yapılacağı için çıkış boyutu 2 olur. Verileri YSA ile öğrenme işleminden geçirir. Şekil 3.5.'de örnek bir tam bağlı katman verilmiştir.



Şekil 3.5. Tam bağlı katman.

3.2.6. DropOut katmanı

Büyük verilerin eğitilmesi sırasında veya veri sayısı çok az ise ezberleme(overfitting) yapmamak için kullanılan katmandır. Bu katmanda, ağdaki rastgele seçilen bazı sinirler etkisiz hale getirilmektedir. Şekil 3.6 (a) da bir ESA'nın orijinal yapısı varken (b)'de Dropout katmanı kullanılmış hali görülmektedir. Değeri genel olarak 0,5 olarak kullanılmaktadır. Bu katman Vgg-16 ağında kullanılmazken AlexNet ağında ise mevcuttur. Bu çalışmada da etkisinin belirlenmesi için denenmiştir.



Şekil 3.6. Bir ESA ağına Dropout katmanı uygulanması. a) Orijinal ESA ağı
b) Dropout katmanı uygulanmış ESA ağı

3.2.7. Sınıflandırma katmanı

Hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktının belirlenmesini sağlar [51]. Bu çalışmada aktivasyon fonksiyonu Softmax kullanılmıştır. Girdinin belirli sınıfa ait olma olasılığını 0–1 aralığında değerler üreterek belirler.

3.3. TRANSFER ÖĞRENME

Günlük hayatta elde edilen bilgileri farklı durumlarda kullanarak bu bilgileri aktarmış oluruz. Karşılaşılan durumların benzerlik içermesi bilgi aktarımına kolaylık sağlar. Literatürde “transfer öğrenme” olarak adlandırılan bu yöntem, önemli bir araştırma konusu haline gelmiştir. Öğrenme aktarımı (Transfer learning) aynı bizim gibi bir

problemi çözerken elde ettiği bilgiyi saklayıp, başka bir problem ile karşılaştığında o bilgiyi kullanmaktadır. Öğrenme aktarımı ile daha az eğitim verisi ile daha yüksek başarı gösteren ve daha hızlı öğrenen ESA modelleri elde edilmektedir. Çalışmada tasarlanan model haricinde transfer öğrenme kullanarak da testler yapılmıştır. Hazır model olarak AlexNet kullanılmıştır. AlexNet, farklı veri kümeleri için yüksek sınıflama başarısı gösterdiği gibi bu çalışmada da yüksek tahmin sonuçları çıkarmıştır.

3.4. VERİ ARTIRMA

Veri artırımı orijinal veriler üzerinde döndürme, kırpma vb. işlemler yaparak yeni veriler üretme işlemidir. Genellikle veri sayısının az olduğu durumlarda kullanılmaktadır. Veri artırma işleminin temel amacı modeli yeterince veri ile destekleyerek daha yüksek başarımlarına ulaşmaktır. Aksi halde küçük veri kümesine sahip modellerin veriyi ezberlemesine neden olarak düşük doğruluk (accuracy) sonuçları çıkabilmektedir. Bu çalışmada kullanılan veri artırma (Data Augmentation) işlemleri hem temel model hem de transfer öğrenme ile oluşturulan model üzerinde uygulanmıştır. Veri artırma uygulanmayan modeller ile yakın sonuçlar çıkmıştır.

3.5. HİPER PARAMETRELER

ESA gibi verilere dayalı makine öğrenme modelleri tasarlanırken, modelde kullanılan algoritmalar veya teknikler tasarımcının karar vermesi gereken bazı parametrelere ihtiyaç duyar. Örneğin, tasarımcı SVM algoritmasında hangi çekirdek fonksiyonunun kullanılacağına karar verir. Aynı şekilde, bir ESA modelinde de mini yığın boyutu, eğitim tur sayısı, öğrenme oranı ve karıştırma (shuffle) gibi parametrelerin ne olacağına karar verir. Genel olarak, başlangıçta bu parametreler için tercihlerin seçimi net ve kesin değildir; problem, veri seti, vb. gibi faktörlere bağlı olarak değişir. Bu nedenle, ne seçilmesi gerektiği, ağı tasarlayan kişiye bırakılmıştır. Problem, veri seti, vb. gibi faktörlere bağlı olarak değişiklik gösteren parametreler, hiper parametreler olarak ifade edilmektedir [52]. Çoğu modelin eğitilmesi uzun zaman alır, hatta eğitimi günler süren modeller vardır. Bu nedenle hiper parametreleri değiştirip uygun değerler bulunarak mümkün olduğunca eğitim süreci kısaltılmaya çalışılmaktadır. Bu çalışmada sürekli değiştirilen hiper parametreler bu başlık altında açıklanmaktadır.

3.5.1. Mini-Batch Boyutu

Öğrenme işleminin her iterasyonunda geri yayılım algoritması, ağırlık değerlerini güncellemektedir. ESA uygulamalarında veri setinde bulunan tüm verileri aynı anda işlemek, bellek ve zaman açısından maliyeti artırır. Bu sebeple veri setinden daha küçük alt kümeler oluşturulmuştur. Verilerin daha küçük alt gruplar halinde işlenmesinin loss değerini arttırdığı fakat zaman ve bellekten kazanıldığı tespit edilmiştir. Mini-batch parametresi; modelin aynı anda kaç veriyi işleyeceği anlamına gelmektedir. Yüksek paket boyutu seçilmesi her iterasyon için kullanılacak veri örneğinin de büyümesi demektir.

3.5.2. Eğitim Tur Sayısı

ESA modeli eğitilirken veri setindeki değerlerin hepsi aynı anda eğitilmez. Alt gruplar halinde işleme alınır. Her parça eğitildikten sonra geri yayılım yapılarak ağırlıklar tekrar hesaplanıp güncellenir. Bu işlem verilerin tamamı kullanılana kadar her adımda tekrarlanır. Bu adımların her birine eğitim turu (epoch) denir. Devir sayısının fazla veya az olması doğruluk oranı hakkında net bir cevap vermez. En uygun değer denenerek bulunur. Ağırlık değerleri adım adım hesaplandığından ilk adımlarda doğruluk düşük, sonraki adımlarda bu doğruluk giderek artacaktır.

3.5.3. Öğrenme Oranı

Geriye yayılım algoritmasında türev alınır ve aradaki fark hesaplanarak öğrenme oranı ile çarpılır. Elde edilen değer önceki ağırlık değeri hesaplaması sonucundan çıkarılarak yeni ağırlık değeri hesaplanmış olur. Öğrenme katsayısının büyük olması salınımına neden olabileceği gibi katsayının küçük olması da öğrenmenin küçük adımlarla gerçekleşmesine neden olacak ve öğrenme süresini uzatacaktır. Bu sebeple öğrenme oranı doğru seçilmelidir. Optimum değeri bulmak için genelde uygulanan en iyi çözüm, başlangıçta değeri yüksek tutup ideal başarımla ulaşana kadar giderek azaltmaktır. Yapılan çalışmalarda öğrenme oranının genelde 0.01 ile 0.0001 arası seçildiği görülmüştür.

3.5.4. Optimizasyon Yöntemi

Bu yöntemde Matlab'da 3 algoritma mevcut olmasına rağmen farklı kişiler tarafından yapılmış algoritmalar da mevcuttur. Bu çalışmada çapraz doğrulama yapılırken Momentumlu Stokastik Eğitim Düşüm (Stochastic Gradient Descent with Momentum-

Sgdm), Adaptif Moment Tahmin (Derived from Adaptive Moment Estimation - Adam) ve Kök Ortalama Kare Yayılımı (RMSprop) kullanılmış ve sonuçları karşılaştırılmıştır.

3.5.4.1. Momentumlu stokastik eğim düşüm (Stochastic Gradient Descent with Momentum-Sgdm)

Sgdm, en dik eğim yolu boyunca optimum seviyede salınım yapabilmektedir. Parametre güncellemesine momentum ekleyerek salınım azaltılabilmektedir. Momentum güncellemesi ile stokastik eğim düşümü Denklem (3.2)'de belirtilmiştir.

$$\theta_{l+1} = \theta_l - \alpha \nabla E(\theta_l) + \gamma(\theta_l - \theta_{l-1}) \quad (3.2)$$

γ önceki düşümün geçerli olan yinelemeye katkısını gösterir. Matlab'da γ değeri 'Momentum' isimli parametre kullanarak belirlenir. Bir sinir ağını eğitmek için stokastik eğim düşümünü momentumla kullanıldığında, solverName 'sgdm' olarak belirtilmelidir.

α öğrenme katsayısının başlangıç değerini belirlemek için 'InitialLearnRate' isimli bağımsız değişken kullanılır [57]. Çalışmada bu değer 0,001 olarak belirlenmiştir.

3.5.4.2. Adaptif Moment Tahmin (Derived from Adaptive Moment Estimation - Adam)

Adam algoritmasında önceki eğimlerin karelerinin üssel olarak azalan ortalamalarının (m_t) saklanması yanında, momentumdaki geçmiş eğimlerin üssel olarak azalan ortalamalarını (v_t) da tutmaktadır [59].

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.3)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3.4)$$

β_1 ve β_2 , hesaplanacak ortalama sayısını bulmaya çalışır. g_t ise eğim düşümünden gelen sayısal değerdir. m_t ve v_t 'nin başlangıçta değerleri sıfıra eşittir.

Sapma doğrulaması için başlangıçta m_t ve v_t değerleri ayarlanmalıdır. Bu parametreler önemlidir. Çünkü öğrenmenin ilk aşamalarında daha iyi bir başarı oranı elde edilmesini sağlar. $\hat{m}_t$ ve $\hat{v}_t$ düzeltilmiş yeni değerleri göstermektedir.

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.5)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.6)$$

Denklem (3.15), Adaptif Moment Tahmin algoritmasının temel formülünü gösterir. ε değeri ise hataların sıfıra bölünmesini engellemek için kullanılmaktadır.

$$\theta_{t+1} = \theta_t - \frac{\alpha \hat{m}_t}{\sqrt{\hat{v}} + \varepsilon} \quad (3.7)$$

Hesaplama yükü olarak verimlidir ve diğer algoritmalara göre daha düşük bellek gereksinimlerine ihtiyaç duyar. Adam, RmsProp ve Momentum gibi gradyan düşürme yöntemlerine benzer şekilde parametrelerini günceller [60].

3.5.4.3. Kare Ortalamalarının Karekökü Yayılımı (Root Mean Square Propagation - RMSprop)


RMSprop, tüm parametreler için aynı öğrenme oranını kullanmaz. Öğrenme katsayısı eğimin değerine göre güncellenir. Diğer optimizasyon algoritmaları, farklı parametreler için aynı öğrenme oranlarını kullanır. Kök ortalama kare yayılımı bu değeri sürekli değiştirerek daha iyi bir eğitim yapmaya çalışmaktadır.

$$v_l = \beta_2 v_{l-1} + (1 - \beta_2) [\nabla E(\theta_1)]^2 \quad (3.8)$$

Kök ortalama kare yayılımı algoritması, her bir parametrenin güncellemelerini ayrı ayrı normalleştirmek için bu hareketli ortalama kullanır. RMSprop, Adadelta gibi farklı öğrenme yöntemleri ile hemen hemen aynı süreçte geliştirilmiş ve agresif küçültme politikasına karşı bir çözüm sunmayı amaçlamıştır [58].

3.6. ÇALIŞMADA KULLANILAN CNN YAPILARI

Çalışmada birçok CNN modeli tasarlanmış ve sonuçları karşılaştırılmıştır. Her modelin katman sayıları ve hiper parametre değerleri optimum değeri bulmak için sürekli değiştirildi. Verilere bir takım ön işlemler uygulandı.



Şekil 3.7. Genel akış diyagramı.

3.6.1. Temel Model

Çalışma için hazırladığımız model 7 evrişim katmanı ve 2 tam bağlantılı katmandan oluşmaktadır. Bu katmanlar arasında da maksimum ortaklama, ReLU ve yığın normalleştirme gibi katmanlar kullanılmıştır. İşlem sırası ve katmanların özellikleri


aşağıda belirtilmiştir:

- Girişte farklı boyutlardaki resimlerden $227 \times 227 \times 3$ boyutunda rastgele resimler kesilmiştir.
- İlk evrişimli katmanda $227 \times 227 \times 3$ boyutuna çevrilmiş olan resimlere 8 adet 3×3 filtre uygulanmıştır. Sonrasında yığın normalleştirme ve ReLU katmanından geçen görüntüler 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama katmanında işlem görmüştür.
- İkinci evrişimli katmanda veriye 3×3 boyutunda 16 tane filtre uygulanıp yine ReLU, 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama ve yığın normalleştirme katmanları uygulanmıştır.
- Üçüncü evrişimli katmana gelen verilere 3×3 boyutunda 32 tane filtre uygulanıp yine ReLU, 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama ve yığın normalleştirme katmanları uygulanmıştır.
- Dördüncü evrişimli katmana ulaşan verilere 3×3 boyutunda 64 adet filtre uygulanıp yine ReLU, 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama ve yığın normalleştirme katmanları uygulanmıştır.
- Beşinci evrişimli katman 3×3 boyutunda 128 tane filtre uygulanıp yine ReLU, 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama ve yığın normalleştirme katmanları uygulanmıştır.
- Altıncı evrişimli katman 3×3 boyutunda 256 tane filtre uygulanıp yine ReLU, 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama ve yığın normalleştirme katmanları uygulanır.
- Yedinci evrişimli katman 3×3 boyutunda 512 tane filtre uygulanıp yine ReLU, 2 adım kaydırmalı 2×2 boyutunda maksimum havuzlama ve yığın normalleştirme katmanları uygulanmıştır. Bu katman sonunda 4608 adet parametre tam bağlantılı katmana girmektedir.
- Tam bağlantılı katmana gelen veriler, bağlantı sayısı 2 olan tam bağlantılı katmanın çıkışına Softmax ve bu katmanın çıkışına da sınıflandırma katmanları bağlanarak eğitim işlemi için gerekli ağ hazırlanmış olur.

Eğitimde kullanılan parametrelerden bizim için önemli olanları öğrenme katsayısı 0,001 mini-yığın boyutu 32, optimizasyon yöntemi Sgdm (Momentumlu stokastik eğitim düşüm) ve maksimum eğitim tur sayısı da 15 olarak seçilmiştir. İlk aşamada verilerin

%70'i eğitim, %30'u test için kullanılarak temel modelin diğer oluşturulan modellerden daha iyi sonuç verdiği gözlemlenmiştir. İkinci aşamada ise ilgili parametre ve katmanlarla oluşturulan modele doğrulama uygulamak için k katlı çapraz doğrulama kullanılmıştır. Sonuçları karşılaştırmak için k değeri 2,3,4,5 ve 10 seçilerek denemeler yapılmıştır. Ayrıca çapraz doğrulama işleminde mevcut yapıya aşırı öğrenme (overfitting) olup olmadığını anlamak için Dropout katmanı eklemiştir. 5 katlı çapraz doğrulama için 5 katın her turda 1 katı test amacıyla kullanılmıştır. Diğer 4 katın %80'i eğitim, kalan %20'si ise doğrulama için kullanılmıştır. Önerilen CNN modeli Şekil 3.7'de paylaşılmıştır.






řekil 3.8. Cinsiyet tahmini iin nerilen CNN modeli.

3.6.2. Veri Artırımı Uygulanmış Model

Temel Modele veri artırma işlemleri uygulanıp aynı parametreler ile oluşturulmuş modeldir. Veri artırma için, görüntünün farklı açılarda döndürülmesi, yatay dikey çevrilmesi, görüntüye gürültü ve renk manipülasyonu ekleme gibi birçok teknik mevcuttur [53]. Yeni görüntüler türetilirken rastgele dönüş aralığı (20,-20) derece olarak belirtilmiştir. Dönme açısı, belirtilen aralıkta rastgele seçilir. Ayrıca belirtilen giriş görüntüsüne uygulanan yatay ve dikey çeviri aralığı (5,-5) olarak belirtilmiştir. Çeviri mesafesi piksel cinsinden ölçülür. Belirtilen aralıklarda yatay ve dikey ekseninde rastgele döndürme işlemleri yapılır.



Şekil 3.9. Veri artırımı ile çoğaltılmış görüntüler.

3.6.3. Transfer Öğrenme Uygulanmış Model

Hazırlanan bu modelde cinsiyetleri sınıflandırmak için önceden eğitilmiş derin öğrenme modellerinin aktarılması olan transfer öğrenme yaklaşımı kullanılmıştır. AlexNet modeli baz alınmıştır. Daha önceden eğitilmiş bu ağın sonundaki 3 katmanı değiştirip kendi veri setimiz ile bu ağı yeniden eğittik. AlexNet' in 5 evrişim ve 3 tam bağlı katmanı vardır. Çalışmada bu katmanlar transfer özellik çıkarıcı katman olarak kullanılmıştır. AlexNet modelinin yapısı Çizelge 3.1'de verilmiştir.

Çizelge 3.1. Matlab'da AlexNet modeli [54].


No	Katman İsmi	Katman Tipi	Açıklama
1	Data	Giriş katmanı (Görüntü)	227×227×3 görüntü, sıfır merkezli normalleştirme
2	conv1	Evrişim	96 11×11×3 evrişim [4 4] kaydırma ve [0 0 0 0] dolgulama
3	relu1	ReLU	ReLU
4	norm1	Çapraz kanal normalleştirme	Eleman başına 5 kanal ile çapraz kanal normalleştirme
5	pool1	Maksimum havuzlama	3×3 maksimum havuzlama [2 2] kaydırma ve [0 0 0 0] dolgulama
6	conv2	Evrişim	256 5×5×48 evrişim, [1 1] kaydırma ve [2 2 2 2] dolgulama
7	relu2	ReLU	ReLU
8	norm2	Çapraz kanal normalleştirme	Eleman başına 5 kanal ile çapraz kanal normalleştirme
9	pool2	Maksimum havuzlama	3×3 maksimum havuzlama [2 2] kaydırma ve [0 0 0 0] dolgulama
10	conv3	Evrişim	384 3×3×256 evrişim [1 1] kaydırma, [1 1 1 1] dolgulama
11	relu3	ReLU	ReLU

Çizelge 3.1. (devam) Matlab'da AlexNet modeli [54].

12	conv4	Evrişim	384 3×3×192 evrişim [1 1] kaydırma, [1 1 1 1] dolgulama
13	relu4	ReLU	ReLU
14	conv5	Evrişim	256 3×3×192 evrişim [1 1] kaydırma ve [1 1 1 1] dolgulama
15	relu5	ReLU	ReLU
16	pool5	Maksimum havuzlama	3×3 maksimum havuzlama [2 2] kaydırma ve [0 0 0 0] dolgulama
17	fc6	Tam bağlantılı	4096 tam bağlantılı katman
18	relu6	ReLU	ReLU
19	drop6	Seyreltme	%50 seyreltme
20	fc7	Tam bağlantılı	4096 tam bağlantılı katma
21	relu7	ReLU	ReLU
22	drop7	Seyreltme	% 50 seyreltme
23	fc8	Tam bağlantılı	1000 tam bağlantılı katman
24	Prob	Softmax	Softmax
25	Output	Sınıflandırma	1000 sınıfla çapraz entropi

Modele transfer öğrenme uygulamak için son 3 katmanı değiştirme yolu izlendi. Çizelge 3.1’de belirtilen AlexNet mimarisinin (17-25) katmanlarından seçilen son üç katman çıkartılmıştır. Yerine temel oluşturulan modeldeki tam bağlı katman, Softmax ve

sınıflandırma katmanları eklenmiştir. AlexNet kendi ağ yapısı ve hiper parametreleriyle eğitimi tamamlar. Fakat çıktı olarak kadın veya erkek olmak üzere 2 sınıf üretmesi beklenildiğinden son üç katman özelleştirilmiştir. Şekil 3.9’da transfer öğrenme ile özelleştirilmiş ağ yapısı görülmektedir.



Şekil 3.10. AlexNet ile transfer öğrenme uygulaması [55].


3.6.4. Transfer Öğrenme ve Veri Artırımı Uygulanmış Model

Temel modele uygulanan veri artırma işlemi ile AlexNet ile yapılan transfer öğrenme modeli birleştirilip yeni bir model oluşturulmuştur. AlexNet'in Çizelge 3.1’de belirtilen (17-25) arasında bulunan katmanların son üçünün yerine temel modelin tam bağlı, Softmax ve sınıflandırıcı katmanları eklenip veri artırma bölümünde açıklanan parametreler eklenmiştir.

3.7. K KATLAMALI ÇAPRAZ DOĞRULAMA


K Katlamalı Çapraz Doğrulama, veri setini çeşitli parçalara ayırarak öğrenme algoritmalarını test etmek ve karşılaştırmak için kullanılan istatistiksel bir yöntemdir. Bu yöntem de veri seti eşit büyüklükte k adet parçaya ayrılır. K-1 parça eğitim ve doğrulama için kullanılırken 1 parçada test için kullanılır ve k defa bu işlem tekrar edilir. Sonuçlanan her turdaki değerler toplanır ve tur sayısı (k)’na bölünerek ortalama

doğruluk değeri bulunur. Bu ortalama değeri bize ağın performansını verir [56]. 10 kat çapraz doğrulama yaygın olarak kullanılmaktadır [57]. Ancak genel olarak k değeri sabit olmamakla birlikte literatürde bu değeri 5 olarak da sıkça kullanılmaktadır [3]. Şekil 4.1’de n sayıda kata sahip çapraz doğrulama yöntemi verilmiştir.



Şekil 4.1. N katlamalı çapraz doğrulama işlemi.

Örneğin, $k = 2$ için 2 kat çapraz doğrulama yapılır. 2 kat çapraz doğrulamada, veri kümesi rastgele d_0 ve d_1 şeklinde iki kümeye ayrılır. d_0 üzerinde eğitim olurken d_1 üzerinde doğrulama işlemi yapılır ardından d_1 üzerinde eğitim yapılır ve d_0 üzerinde doğrulama işlemi yapılır. Çalışmada çeşitli optimizasyon yöntemleri ile $k=2,3,4,5,10$ değerleri için çapraz doğrulama yapılmış ve sonuçları karşılaştırılmıştır. Örneğin $k=5$ için her turda bir kat test için kullanılmıştır. Kalan 4 katın %80’i eğitim için, %20’si ise doğrulama için kullanılmıştır. Bu süreç farklı turlarda farklı katların test için kullanılması şeklinde devam etmektedir. Şekil 4.2 de $k=5$ için bu işlem şematik olarak gösterilmiştir.



Şekil 4.2. K=5 için çapraz doğrulama işlemi.


4. BULGULAR VE TARTIŞMA

Model eğitim ve doğrulamasında tamamlanan her turun süreleri, iterasyon sayıları, öğrenme algoritmaları ve başarı oranları bu bölümde paylaşılmıştır. Çalışmada hiper parametre, katman sayıları ve filtre boyutlarında en iyi sonuçları elde edebilmek için değişiklikler yapılmıştır. Değiştirilen parametreler Çizelge 4.1’de verilmiştir.

Çizelge 4.1. Değiştirilen parametreler ve değerleri.

Hiper Parametre	Aralık
Öğrenme Oranı	[0.001 0.0001]
Mini Yığın Boyutu	[10 32 64]
Eğitim Tur Sayısı	[6 10 12 15 20]

Hiper parametrelerdeki bu değişiklikler her katman ve filtre sayısı değişikliğinde tekrar uygulandı. En iyi sonuçları 7 evrişim katmanı ve 2 tam bağlantılı katmandan oluşan model vermiştir. Bu katmanlar arasında da maksimum ortaklama, ReLU ve yığın normalleştirme gibi katmanlar kullanılmıştır. Önerilen modelin eğitim ve başarı sonuçları Şekil 4.3’ de verilmiştir.



Şekil 4.3. Önerilen modelin doğruluğu ve iterasyon sayısı.

Sonuçların gerçek kişilerin tahminlerinden daha iyi olup olmadığını anlamak için 100 kişiye 100 farklı parmak ucu görüntüsünün bulunduğu bir anket uygulanmış ve cinsiyetlerini tahmin etmeleri istenmiştir. Katılımcılar ortalama %55,34 doğruluk

oranına ulaşabilmişlerdir. Önerilen model %86,34 doğruluk oranı ile daha iyi tahmin yapabilmıştır. Örnek anket görüntüsü Şekil 4.4’de verilmiştir.

Resimde gördüğünüz parmak hangi cinsiyete aittir? *



☐ ERKEK

☐ KADIN


Şekil 4.4. Uygulanan ankette soru örneği.

Anketin ortalama değerleri, katılımcı sayısı, en iyi tahmin sonucu gibi değerler grafik olarak Şekil 4.5’de paylaşılmıştır.

Analizler

Ortalama 55,34/100 puan	Ortanca değer 55/100 puan	Aralık 47 - 65 puan
----------------------------	------------------------------	------------------------

Toplam puan dağılımı



Şekil 4.5. Katılımcıların tahmin başarıları.

Toplanan görüntüler sürekli değiştiği için farklı veri boyutları ile testler yapılmıştır. Bunun sonucunda veri boyutunun başarı oranına etkisi de analiz edilmiştir. Eğitim tur sayısı, öğrenme oranı, mini yığın boyutu, evrişim katmanı sayılarının veri boyutu ile ilişkisi 4 farklı model ile incelenmiştir. T.M (Temel Model), V.A.U.M (Veri Artırımı Uygulanmış Model), T.Ö.U.M (Transfer Öğrenme Uygulanmış Model), T.Ö.V.U.M (Transfer Öğrenme ve Veri Artırımı Uygulanmış Model) ile yapılan farklı testler ve başarı oranları Çizelge 4.2’ de paylaşılmıştır.

Çizelge 4.2. Veri, katman ve hiper parametre değerlerinin sonuçlara etkisi.

Model	Değerler							
	995 Kadın ve 1115 erkek parmak ucu görüntüsü	558 Kadın ve 550 erkek parmak ucu görüntüsü						
Eğitim Tur Sayısı	15	10	10	6	12	12	12	20
Öğrenme Oranı	0.0001	0.001	0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
Mini Yığın Boyutu	32	32	64	10	10	10	10	10
Evrişim Katmanı Sayısı	7	7	7	3	3	5	7	3
T.M Başarı O.	86,39	76,58	82,59	73,19	76,81	86,75	81,93	78,92
V.A.U.M Başarı O.	84,81	75,16	70,32	72,29	79,82	80,72	74,40	72,89
T.Ö.U. M Başarı O.	81,65	77,85	75,79	88,25	87,35	75,90	88,55	87,95
T.Ö.V.U.M	81,26	72,15	65,43	81,63	91,57	86,75	86,45	86,75

Tam veri ile önerilen model en iyi sonucu 15 eğitim tur sayısı, 0.0001 öğrenme oranı ve 32 mini yığın boyutu ile almıştır. Bu modelde 7 evrişim katmanı kullanılmış ve filtre sayısı 16,32,64,128,256 ve 512 olmak üzere artırılarak kademeli derinleştirilmiştir. Bu değerler ile yapılan testler sonucunda %86,39 başarı oranı elde edilmiştir. Daha az sayıda görüntü içeren veri seti ile yapılan veri artırma işlemi uygulanmış model 12 eğitim tur sayısı, 0.0001 öğrenme oranı ve 10 mini yığın boyutu ile %80,72 maksimum başarı elde edilmiştir. Bu modelde 5 evrişim katmanı kullanılmış ve filtre sayısı giderek arttırılmıştır. Transfer Öğrenme işleminden geçirilen ve az sayıda veri kullanılan model %88,55 başarı elde etmiştir. 7 evrişim katmanı ve önerilen modeldeki filtre sayıları kullanılmıştır. Hem transfer öğrenme işlemi hem de veri artırma işlemleri uygulanan model en iyi sonucu az veri ile vermiştir. Bu modelde 3 evrişim katmanı kullanılmış ve %91,57 tahmin doğruluğu yakalanmıştır. Görülmektedir ki az veri kullanılan çalışmalarda veri artırma uygulanan modeller daha iyi sonuç vermiş fakat orijinal veri boyutu arttırıldığında aynı performansı gösterememiştir. Maksimum sayıda veri ile yapılan testlerde tüm en uygun şekle sokma işlemleri yapılmış ve az sayıda veri ile yapılan testlere yakın veya daha iyi sonuçlar bulunmuştur. Öğrenme işlemi adımlarında renk verisinin önemli olup olmadığını, önemli ise etkisinin analiz edilmesi için görüntüler siyah-beyaz formatına çevrilip T.M ve V.A.U.M ile evrişim katman sayıları değiştirilip testler yapılmıştır. Yapılan testlerde 995 erkek ve 1115 kadın parmak ucu görüntüsü kullanılmıştır. Mini yığın boyutu 32, öğrenme oranı 0.001 ve eğitim tur sayısı 12 olarak seçilmiştir. Testlerin sonucu Çizelge 4.3’de paylaşılmıştır.

Çizelge 4.3. Siyah beyaz renk dönüşümün sonuçlara etkisi.

Model	Eğitim Başarısı (3Evrişim)	Eğitim Başarısı (5Evrişim)	Eğitim Başarısı (7Evrişim)
T.M Başarı O.	67,88	70,09	77,85
V.A.U.M Başarı O.	64,24	58,86	57,65

Başarı oranlarının renkli görüntüler ile yapılan testlere göre daha düşük çıkmasındaki sebebin kadın tırnaklarındaki kına, oje gibi faktörler ile tırnak etindeki renklerin farklılığından kaynaklandığı saptanmıştır.

Tüm modellerin eğitim ve testleri tamamlandıktan sonra en iyi sonuç veren model ile k katlamalı çapraz doğrulama yapılmıştır. Sonuçların karşılaştırılması için Sgdm, Adam ve Rmsprop optimizasyon algoritmaları 2,3,4,5,10 kat çapraz doğrulama yapıp en iyi sonuç en iyi süreyle alınmaya çalışılmıştır. Eğitim, test ve doğrulama işlemleri 8 gb ram, GT 740M (2gb, 128 bit) ekran kartı ve Intel 3317U işlemciye sahip dizüstü bilgisayar ile yapılmıştır. En iyi sonucu Sgdm algoritması ile k=10 değeri için alınmıştır (Çizelge 4.4). Temel model de alınan %86,39 değer artırılarak %87,53 oranla daha iyi başarı elde edilmiştir. Ayrıca 10 kat çapraz doğrulamada diğer algoritmalara göre daha hızlıdır.

Çizelge 4.4. 10 kat çapraz doğrulama.

Optimizasyon Algoritması	Doğruluk Oranı	İterasyon Sayısı	Tamamlanma Süresi
Sgdm	87,53	885	1:16:24
Adam	84,02	885	2:36:03
Rmsprop	82,36	885	01:19:56

k değeri yarıya düşürülüp 5 yapıldığında eğitim için harcanan sürenin 10 kat çapraz doğrulama ile yapılan testlere göre %53,9 daha kısaldığı görülmüştür. Eğitim ve doğrulama işlem süresinde önemli bir düşüş olmasına rağmen doğruluk oranının %1,28 düştüğü saptanmıştır.

Çizelge 4.5. 5 kat çapraz doğrulama.

Optimizasyon Algoritması	Doğruluk Oranı	İterasyon Sayısı	Tamamlanma Süresi
Sgdm	86,25	780	00:35:36
Adam	82,79	780	00:35:55
Rmsprop	80,09	780	00:34:13

4 kat çapraz doğrulamada ise 5 kat çapraz doğrulamaya göre doğruluk oranı Sgdm algoritmasında %0,62 düşmüş ve harcanan süre ise 8 dk azalmıştır. Diğer sonuçlar da incelendiğinde Sgdm algoritmasında k değeri azaldıkça başarı oranında çok az miktarda düşüşler yaşandığı görülmüştür. Ayrıca 4 kat çapraz doğrulamada en hızlı sonuç veren Adam algoritması olmuştur.

Çizelge 4.6. 4 kat çapraz doğrulama.

Optimizasyon Algoritması	Doğruluk Oranı	İterasyon Sayısı	Tamamlanma Süresi
Sgdm	85,63	735	00:27:31
Adam	82,65	735	00:26:01
Rmsprop	78,72	735	00:26:07

Çizelge 4.7. 3 kat çapraz doğrulama.

Optimizasyon Algoritması	Doğruluk Oranı	İterasyon Sayısı	Tamamlanma Süresi
Sgdm	83,98	645	00:16:44
Adam	83,45	645	00:17:31
Rmsprop	76,01	645	00:11:37

2 kat çapraz doğrulama en hızlı ve en düşük sonuçların bulunduğu çapraz doğrulama yöntemi olmuştur. Fakat tüm algoritmalar eğitim sürelerinin düşüklüğü ve iterasyon sayıları dikkate alındığında oldukça iyi sonuçlar vermiştir.


Çizelge 4.8. 2 kat çapraz doğrulama.

Optimizasyon Algoritması	Doğruluk Oranı	İterasyon Sayısı	Tamamlanma Süresi
Sgdm	80,47	480	00:08:23
Adam	77,91	480	00:08:42
Rmsprop	74,83	480	00:08:11

Tüm sonuçlar incelendiğinde Rmsprop algoritmasının tüm k değerleri için en düşük sonucu verdiği görülmüştür. Buna rağmen 2,3,5 kat çapraz doğrulama işlemlerinde en hızlı algoritma olmuştur. Adam algoritmasının başarı oranları ise tüm testlerde Sgdm ve Rmsprop algoritmalarının ortasında olmuştur. Tüm sonuçlar analiz edildiğinde Adam algoritması diğer algoritmalara göre ortalama bir süreyle eğitim ve testleri tamamlamıştır. Fakat 10 kat çapraz doğrulamada 2 saat 36 dakika ile en yavaş algoritma olmuştur. Diğer çapraz doğrulama sonuçları incelendiğinde adam algoritmasının k değerine bağlı olarak başarı oranları ve eğitim sürelerinde lineer bir değişim mevcutken

10 kat apraz doęrulamada beklenenden daha yavař kaldığı tespit edilmiştir. Genel bir deęerlendirme yapıldığında başarı oranında Sgdm > Adam > RmsProp ilişkisi varken eğitim ve doęrulama süreleri arasında Adam > RmsProp > Sgdm şeklinde bir ilişki mevcuttur. En iyi başarı 10 kat apraz doęrulama ile elde edilmiştir. Her turda 1 kat test için kullanılmış, dięer katlar eğitim ve test için ayrılmıştır. Eğitilen bu modelde %87,53 başarı oranı elde edilmiştir.

Eğitilen modelin sonuçlarını görmek ve istenilen parmak görüntüsü üzerinde tahmin yapabilmek için Matlab kullanılarak bir uygulama daha geliştirilmiştir (Şekil 4.6). Kullanıcıya 5 erkek ve 5 kadın parmak ucu görüntüsü ön tanımlı olarak verilmiştir. Ek olarak kullanıcı kendi seçtiğı görseli de yükleyebilir ve testlerini yapabilir.



Şekil 4.6. Parmak ucu görüntüsünden cinsiyet tahmini yapabilen Matlab uygulaması.

5. SONUÇLAR VE ÖNERİLER

Günümüzde biyometrik tanıma ve derin öğrenme alanlarının giderek popüler olması araştırmacılara farklı çalışma alanları sağlamıştır. Çalışma da yüz görüntülerinden cinsiyet tahmin etmede çok iyi başarımlar sonuçları elde eden CNN modellerinin parmak ucu görüntülerinden cinsiyet tahmin etmedeki performansı analiz edilmiştir. Başarı oranını artırmak için katman sayıları, filtre sayıları ve hiper parametre değerleri değiştirilip test edilmiştir. 4 farklı model üretilmiş ve her bir modelin gerçek kişi tahminlerinden daha iyi tespit yapabildiği görülmüştür.

Literatürde Adience, IMDB, WIKI gibi hazır veri setleri çok fazla kullanılmaktadır [29], [22]. Ayrıca birçok veri setini birleştirerek yeni veri seti elde eden çalışmalar da mevcuttur [16], [27]. Bu çalışmada, veriler katılımcılardan tek tek toplanmış ve yeni bir veri seti oluşturulmuştur. Bu konuda araştırma yapmak isteyen araştırmacılar için veri seti Kaggle'a yüklenmiştir [61].

Çalışmada önerilen temel model 7 evrişim katmanı ve 2 tam bağlantılı katmandan oluşmaktadır. Bu katmanlar arasında da maksimum ortaklama, ReLU ve yığın normalleştirme gibi katmanlar kullanılarak %86,39 başarı elde edilmiştir. AlexNet mimarisinin son 3 katmanı çıkartılıp, bu katmanlar yerine temel modeldeki tam bağlı katman, Softmax ve sınıflandırıcı katmanları eklenerek bir transfer öğrenme modeli oluşturulmuştur. Bu oluşturulan model ile 81,65 başarı oranı elde edilmiştir. Transfer Öğrenme modeline veri artırma uygulandığında başarı oranı azalarak %81,65 olmuştur. Temel modele veri artırma uygulandığında ise bu oran %84,81 olmuştur.

Tüm modellerin eğitim ve testi tamamlanarak, en iyi sonuçlar elde edildikten sonra en yüksek sonuç alınan temel modele k katlamalı çapraz doğrulama uygulanmıştır. Sgdm algoritmasıyla yapılan 10 kat çapraz doğrulama 1 saat 16 dakika sürmüş ve 885 iterasyonda %87,53 doğruluk oranı elde edilmiştir.

Ayrıca Şekil 4.6'da görüldüğü üzere kullanıcı ön tanımlı bir erkek parmak ucu görüntüsü seçmiş ve önerilen model %99,23 doğruluk oranıyla bu görüntünün bir erkeğe ait olduğunu ayırt edebilmiştir. Sonuç olarak eğitim ve testlerde yüksek sonuçlar alınan modelin pratikte de yüksek tahmin oranlarıyla başarılı olduğu görülmüştür.

Elde edilen sonuçlara göre önerilen modelin parmak ucu görüntülerinden cinsiyet tanıma problemi için kullanılabileceği ayrıca orijinal eğitim ve test verileri sınırlı olsa bile oluşturulan tüm modellerin %80'in üzerinde başarı elde etmeleriyle birlikte ESA yapılarının çok etkili bir yöntem olduğu ortaya konulmuştur. İleride yapılacak çalışmalarda bizim oluşturduğumuz veri seti genişletilerek farklı derin ağ mimarileriyle başarı oranının artırılması önerilmektedir. Bu çalışmada önerilen yöntem yeni biyometrik tanıma sistemlerinde kullanılabileceği gibi var olan biyometrik tanıma sistemlerinde ön işlem için filtreleme olarak kullanılabilir.



6. KAYNAKLAR

- [1] E.Alpaydın, *Introduction to Machine Learning*, 2. baskı, Londra, İngiltere: MIT Press, 2010, böl. 1, ss. 4-17.
- [2] C. M. Bishop, *Pattern Recognition and Machine Learning*, 1. baskı, New York, Amerika: Springer Science + Business Media, 2006, böl. 1, ss. 12-55.
- [3] G. Levi ve T. Hassner, “Age and gender classification using convolutional neural networks,” *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, Boston, Amerika, 2015, ss. 34-42.
- [4] E. Eiding, R. Enbar ve T. Hassner, “Age and gender estimation of unfiltered faces,” *IEEE Transactions on Information Forensics and Security*, c. 9, sayı. 12, ss. 2170–2179, 2014.
- [5] C.Szegedy, W.Liu, Y.Jia, P.Sermanet, S.Reed, D.Anguelov, D.Erhan, V.Vanhoudke ve A.Rabinovich, “Going deeper with convolutions,” *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, Amerika, 2015, ss. 1-9.
- [6] Anonim. (2020, 24 Mayıs). *Flickr photos* [Online]. Erişim: <https://www.flickr.com/photos/tags/yahoo>
- [7] E. Cengil, A. Çınar ve Z. Güler, "A GPU-based convolutional neural network approach for image classification," *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, Malatya, Türkiye 2017, ss. 1-6.
- [8] A. Sengur, Y. Akbulut, Y. Guo ve V.Bajaj,” Classification of amyotrophic lateral sclerosis disease based on convolutional neural network and reinforcement sample learning algorithm,” *Health information science and systems*, c. 9, sayı. 5, ss. 1-7, 2017.
- [9] R. Girshick, J. Donahue, T. Darrell ve J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation,” *2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, Amerika, 2014, ss. 580–587.
- [10] S. Jialin Pan ve Q. Yang, “A Survey on Transfer Learning,” *IEEE Transactions on Knowledge and Data Engineering*, c. 22, sayı. 1, ss. 1345–1359, 2010.
- [11] B. Koçer, “Transfer Öğrenmede Yeni Yaklaşımlar,” Doktora tezi, Bilgisayar

Mühendisliği, Fen Bilimleri Enstitüsü, Selçuk Üniversitesi, İstanbul, Türkiye, 2012.

- [12] P. Rodríguez, G. Cucurull, J. M. Gonfaus, F. X. Roca ve J. González, “Age and gender recognition in the wild with deep attention,” *Pattern Recognition*, c. 72, ss. 563–571, 2017.
- [13] E. Illouz, E. David ve N. S. Netanyahu, “Handwriting based gender classification using end-to-end deep neural networks,” *27th International Conference on Artificial Neural Networks*, Rodos, Yunanistan, 2017, ss. 613–621.
- [14] N. R. Baek, S. W. Cho, J. H. Koo, N. Q. Truong ve K. R. Park. (2019, 31 Ekim). *Multimodal camera-based gender recognition using human-body image with two-step reconstruction network* [Online]. Erişim: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8782507>.
- [15] T. Liu, X. Ye ve B. Sun, “Combining Convolutional Neural Network and Support Vector Machine for Gait-based Gender Recognition,” *2018 Chinese Automation Congress (CAC)*, Xi'an, Çin, 2019, ss. 3477–3481.
- [16] S. C. Nistor, A. C. Marina, A. S. Darabant ve D. Borza, “Automatic gender recognition for ‘in the wild’ facial images using convolutional neural networks,” *13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)*, Cluj-Napoca, Romanya, 2017, ss. 287–291.
- [17] M. H. Gauswami ve K. R. Trivedi, “Implementation of machine learning for gender detection using CNN on raspberry Pi platform,” *2nd International Conference on Inventive Systems and Control (ICISC)*, Coimbatore, Hindistan, 2018, ss. 608–613.
- [18] Y. Akbulut, A. Şengür ve S. Ekici, “Gender recognition from face images with deep learning,” *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, Malatya, Türkiye, 2017, ss. 1–4.
- [19] I. Viedma ve J. Tapia, “Deep gender classification and visualization of near-infra-red periocular-iris images,” *2018 IEEE International Conference on Image Processing, Applications and Systems (IPAS)*, Sophia Antipolis, Fransa, 2018, ss. 73–78, 2018.
- [20] S. Hosseini, S. H. Lee, H. J. Kwon, H. Il Koo ve N. I. Cho, “Age and gender classification using wide convolutional neural network and Gabor filter,” *2018 International Workshop on Advanced Image Technology (IWAIT)*, Chiang Mai, Tayland, 2018, ss. 1–3.

- [21] J. H. Lee, Y. M. Chan, T. Y. Chen ve C. S. Chen, "Joint estimation of age and gender from unconstrained face images using lightweight multi-task CNN for mobile applications," *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, Miami, Amerika, 2018, ss. 162–165.
- [22] B. Kabasakal ve E. Sumer, "Gender recognition using innovative pattern recognition techniques," *2018 26th Signal Processing and Communications Applications Conference (SIU)*, İzmir, Türkiye, 2018, ss. 1–4.
- [23] J. Van De Wolfshaar, M. F. Karaaba ve M. A. Wiering, "Deep convolutional neural networks and support vector machines for gender recognition," *2015 IEEE Symposium Series on Computational Intelligence*, Cape Town, Güney Afrika, 2015, ss. 188–195.
- [24] Á. Morera, Á. Sánchez, J. F. Vélez, A. B. Moreno, "Gender and Handedness Prediction from Offline Handwriting Using Convolutional Neural Networks", *Hindawi Complexity*, c. 2018, ss. 1-14, 2018.
- [25] K. Ito, H. Kawai, T. Okano ve T. Aoki, "Age and Gender Prediction from Face Images Using Convolutional Neural Network," *2018 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*, Honolulu, Amerika, 2018, ss. 7-11.
- [26] S. Arora ve M. P. S. Bhatia, "A Robust Approach for Gender Recognition Using Deep Learning," *2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Bangalore, Hindistan, 2018, ss. 1-6.
- [27] M. Afifi, "11K Hands: Gender recognition and biometric identification using a large dataset of hand images," *Multimedia Tools and Applications*, c. 78, sayı. 15, ss. 20835–20854, 2019,
- [28] I. B. Barbosa, T. Theoharis, C. Schellewald ve C. Athwal, "Transient biometrics using finger nails," *2013 IEEE Sixth International Conference on Biometrics: Theory, Applications and Systems (BTAS)*, Arlington, Amerika, 2013, ss. 1-6
- [29] E. Karakaş, "Derin sinir ağlarının füzyonu ile yüz imgelerinden yaş grubu ve cinsiyet sınıflandırma," Yüksek lisans tezi, Elektrik ve Elektronik Mühendisliği, Fen Bilimleri Enstitüsü, Atatürk Üniversitesi, Erzurum, Türkiye, 2019.
- [30] G. Gündüz, "Derin öğrenme ile fotoğraftan yaş ve cinsiyet tespiti," Yüksek lisans tezi, Endüstri Mühendisliği, Fen Bilimleri Enstitüsü, Sakarya Üniversitesi, Sakarya, Türkiye,

2019.

- [31] Y. Cui, T. Pan, S. Chen ve X. Zou, "A gender classification method for Chinese mitten crab using deep convolutional neural network," *Multimedia Tools and Applications*, c. 79, sayı. 11–12, ss. 7669–7684, 2020.
- [32] X. Liu, Y. Zou, H. Kuang ve X. Ma, "Face image age estimation based on data augmentation and lightweight convolutional neural network," *Symmetry (Basel)*, c. 12, sayı. 1, ss. 146, 2020.
- [33] A. Kuehlkamp, B. Becker ve K. Bowyer, "Gender-from-iris or gender-from-mascara?," *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Santa Rosa, Kaliforniya, 2017, ss. 1151-1159.
- [34] L. Geng, K. Zhang, X. Wei ve X. Feng, "Soft Biometrics in Online Social Networks: A Case Study on Twitter User Gender Recognition," *2017 IEEE Winter Applications of Computer Vision Workshops (WACVW)*, Santa Rosa, Amerika, 2017, ss. 1-8.
- [35] G. Antipov, S. A. Berrani ve J. L. Dugelay, "Minimalistic CNN-based ensemble model for gender prediction from face images," *Pattern Recognition Letters*, c. 70, ss. 59–65, 2016.
- [36] F. Juefei-Xu, E. Verma, P. Goel, A. Cherodian ve M. Savvides, "Deepgender: occlusion and low resolution robust facial gender classification via progressively trained convolutional neural networks with attention," *2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Las Vegas, Amerika, 2016, ss. 136-145.
- [37] K. Zhang, L. Tan, Z. Li ve Y. Qiao, "Gender and smile classification using deep convolutional neural networks," *2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Las Vegas, Amerika, 2016, ss. 739-743.
- [38] H. A. Perlin ve H. S. Lopes, "Extracting human attributes using a convolutional neural network approach," *Pattern Recognition Letters*, c. 68, ss. 250–259, 2015.
- [39] G. Antipov, M. Baccouche, S. A. Berrani ve J. L. Dugelay, "Effective training of convolutional neural networks for face-based gender and age prediction," *Pattern Recognition*, c. 72, ss. 15–26, 2017.
- [40] A. Rattani, N. Reddy ve R. Derakhshani, "Convolutional neural network for age classification from smart-phone based ocular images," *2017 IEEE International Joint*

Conference on Biometrics (IJCB), Denver, Amerika, 2017, ss. 756-761.

- [41] D. Doukhan, J. Carrive, F. Vallet, A. Larcher ve S. Meignier, "An open-source speaker gender detection framework for monitoring gender equality," *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Calgary, Kanada, 2018, ss. 5214-5218.
- [42] Z. Qawaqneh, A. A. Mallouh ve B. D. Barkana, "Age and gender classification from speech and face images by jointly fine-tuned deep neural networks," *Expert Systems with Applications*, c. 85, ss. 76–86, 2017.
- [43] T. Choubisa, M. Kashyap, R. N. Rithesh ve S. B. Mohanty, "Direction and gender classification using convolutional neural network for side-view images captured from a monitored trail," *2017 Fourth International Conference on Image Information Processing (ICIIP)*, Shimla, Hindistan, 2017, ss. 1-6.
- [44] A. Anand, R. D. Labati, A. Genovese, E. Muñoz, V. Piuri ve F. Scotti, "Age estimation based on face images and pre-trained convolutional neural networks," *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*, Honolulu, Amerika, 2017, ss. 1-7.
- [45] T. V. Janahiraman ve P. Subramaniam, "Gender classification based on asian faces using deep learning," *2019 IEEE 9th International Conference on System Engineering and Technology (ICSET)*, Shah Alam, Malezya, 2019, ss. 84-89.
- [46] P. Smith ve C. Chen, "Transfer learning with deep cnns for gender recognition and age estimation," *2018 IEEE International Conference on Big Data*, Seattle, Amerika, 2019, ss. 2564–2571.
- [47] D. Yaman, F. I. Eyiokur, N. Sezgin ve H. K. Ekenel, "Age and gender classification from ear images," *2018 International Workshop on Biometrics and Forensics (IWBF)*, Sassari, İtalya, 2018, ss. 1-7.
- [48] E. Ceyhan ve Ş. Sağıroğlu, "A New Intelligent System for Predicting Gender from Fingerprint," *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, c. 7, sayı. 1, ss. 677-688, 2019.
- [49] R. Shu, J. Brofos, F. Zhang, H. H. Bui, M. Ghavamzadeh ve M. Kochenderfer, "Stochastic video prediction with conditional density estimation," *Fourteenth European Conference on Computer Vision (ECCV-2016)*, Amsterdam, Hollanda, 2016, c. 1, ss. 1–

3.

- [50] F. Juefei-Xu, E. Verma ve M. Savvides, “Deepgender2: A generative approach toward occlusion and low-resolution robust facial gender classification via progressively trained attention shift convolutional neural networks (PTAS-CNN) and deep convolutional generative adversarial networks (DCGAN),” *Advances in Computer Vision and Pattern Recognition*, c. PartF1, ss. 183–218, 2017.
- [51] A. Koyun ve E. Afşin, “Derin öğrenme ile iki boyutlu optik karakter tanıma,” Yüksek lisans tezi, Bilgisayar Mühendisliği, Süleyman Demirel Üniversitesi, Isparta, Türkiye, 2017.
- [52] N. Çarkacı. (2018, 22 Ocak). *Derin öğrenme uygulamalarında en sık kullanılan hiper-parametreler* [Online]. Erişim: <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>.
- [53] M. B. Er, “Emotion analysis in Turkish music with machine learning,” Doktora tezi, Bilgisayar Mühendisliği, Fen Bilimleri Enstitüsü, Maltepe Üniversitesi, İstanbul, Türkiye, 2019.
- [54] Anonim. (2019, 17 Ocak). *AlexNet convolutional neural network* [Online]. Erişim: <https://www.mathworks.com/help/deeplearning/ref/alexnet.html>.
- [55] S. Vishwesh. (2019, 3 Haziran). *PyTorch for beginners: image classification using pre-trained models* [Online]. Erişim: <https://www.learnopencv.com/pytorch-for-beginners-image-classification-using-pre-trained-models>.
- [56] P. Refaeilzadeh, L. Tang, H. Liu, “Cross-Validation,” *Encyclopedia of Database Systems*, 1. baskı, Berlin, Almanya: Springer, 2009, ss. 532-538.
- [57] Anonim. (2017, 1 Ağustos). *Cross validation – statistics* [Online]. Erişim: [http://en.wikipedia.org/wiki/Cross-validation_\(statistics\)](http://en.wikipedia.org/wiki/Cross-validation_(statistics)).
- [58] X. Liu, J. Li, C. Hu ve J. Pan, "Deep convolutional neural networks-based age and gender classification with facial images," *2017 First International Conference on Electronics Instrumentation & Information Systems (EIIS)*, Harbin, Çin, 2017, ss. 1-4.
- [59] S. Ruder. (2016, 19 Ocak). *An overview of gradient descent optimization algorithms* [Online]. Erişim: <https://ruder.io/optimizing-gradient-descent>.
- [60] A. Gülcü ve Z. Kuş, "Konvolüsyonel sinir ağlarında hiper-parametre optimizasyonu

yöntemlerinin incelenmesi", *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, c. 7, sayı. 2, ss. 503-522, 2019.

- [61] K. Sırma. (2020, 3 Eylül). *Fingertip images* [Online]. Erişim: <https://kaggle.com/keremsirma/fingertip-images>.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Kerem Sırma
Doğum Tarihi ve Yeri :
Yabancı Dili : İngilizce
E-posta :

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Y. Lisans	Bilgisayar Müh.	Düzce Üniversitesi	2021
Lisans	Bilgisayar Müh.	Düzce Üniversitesi	2017
Lise		Küçükköy Anadolu Teknik Lisesi	2013

YAYINLAR

Sırma K., Erdoğan P., Gender Prediction From Fingertip Images Using Convolutional Neural Networks (Journal of Scientific Reports-A 2020)