

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKLIK VE CİNSİYET TABANLI AKILLI REKLAM
GÖRÜNTÜLEME SİSTEMİ

BURAK KABASAKAL

YÜKSEK LİSANS TEZİ

2018

UZAKLIK VE CİNSİYET TABANLI AKILLI REKLAM GÖRÜNTÜLEME SİSTEMİ

DISTANCE AND GENDER BASED SMART ADVERTISING DISPLAY SYSTEM

BURAK KABASAKAL

Başkent Üniversitesi
Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin
BİLGİSAYAR Mühendisliği Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır.

2018

“Uzaklık ve Cinsiyet Tabanlı Akıllı Reklam Görüntüleme Sistemi” başlıklı bu çalışma, jürimiz tarafından, 25/06/2018 tarihinde, **BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Başkan : Doç. Dr. Uğur Murat LELOĞLU

Üye (Danışman) : Dr. Öğr. Üyesi Emre SÜMER

Üye : Dr. Öğr. Üyesi Selay ILGAZ SÜMER

ONAY

..../07/2018

Prof. Dr. Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü



BAŞKENT ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 03/07/2018

Öğrencinin Adı, Soyadı: Burak KABASAKAL

Öğrencinin Numarası: 21320093

Anabilim Dalı: BİLGİSAYAR MÜHENDİSLİĞİ

Programı: BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS

Danışmanın Unvanı/Adı, Soyadı: Dr. Öğr. Üyesi Emre SÜMER

Tez Başlığı: Uzaklık ve Cinsiyet Tabanlı Akıllı Reklam Görüntüleme Sistemi

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 63 sayfalık kısmına ilişkin, 03/07/2018 tarihinde şahsım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 1'dir.

Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

Onay

... /07/2018

Dr. Öğr. Üyesi Emre SÜMER

TEŞEKKÜR

Sayın Dr. Öğr. Üyesi Emre SÜMER'e (tez danışmanı), çalışmanın sonuca ulaşmasında ve karşılaşılan güçlüklerin aşılmasında her zaman yardımcı ve yol gösterici olduğu için,

Sayın Engin TAMER'e tezin her aşamasında yaptığı destek ve yardımları için,

Tezin yazım kısmında desteklerinden dolayı annem Demet KABASAKAL ve eşim Aybike KABASAKAL'a,

Tüm bu süreçte bana destekleriyle yanımda olan aileme ve arkadaşlarıma desteklerinden dolayı teşekkür ederim.

ÖZ

UZAKLIK VE CİNSİYET TABANLI AKILLI REKLAM GÖRÜNTÜLEME SİSTEMİ

Burak KABASAKAL

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Son yirmi yılda artan teknolojik gelişmelere paralel olarak örüntü tanıma ve bilgisayarlı görme alanlarını kullanan ve gündelik hayata entegre olan birçok çalışma ve araştırma bulunmaktadır. Bu tezde, gerçek zamanlı olarak kamera kaynağından alınan yayın üzerinde tespit edilen yüz görüntülerinden elde edilen cinsiyet bilgisine ve kameraya uzaklığına bağlı olarak çalışan akıllı reklam görüntüleme sistemi geliştirilmiştir.

Sistem temelde iki ayrı kısımdan oluşmaktadır. İlk kısımda kamera kaynağından alınan veriler, canlı yayındaki çerçeveler işlendikten sonra algılanan yüzlerden cinsiyet tespiti ve uzaklık kestirimi yapılarak canlı yayına eklenmektedir. Sistemin ikinci kısmında ise algılanan yüze ait resim, cinsiyet etiketi ve kameraya uzaklık bilgisi reklam bilgisinin gösterileceği uygulamaya web servis yolu ile iletilip, veritabanına kaydedilmektedir. Sistem için önceden tanımlanmış süre içerisinde veritabanında bulunan yüz ve uzaklık bilgileri analiz edilerek farklı detay seviyelerinde reklam gösterimi yapılmaktadır. Analiz işleminde, sistem için tanımlanmış süre zarfında veritabanından elde edilen veriler doğrultusunda cinsiyet ve uzaklığa bağlı olarak farklı ilgi seviyelerinde reklam gösterimi gerçekleştirilmektedir. Sistemin verimli çalışması için cinsiyet tespitinin doğru yapılması oldukça önem arz etmektedir.

Çalışmada, geliştirilen yüz algılama sınıflandırıcısıyla beraber cinsiyet tespit işlemi için Fisher Yüz Algoritması (Fisherfaces), Destek Vektör Makineleri (SVM) ve Evrimsel Sinir Ağları (CNN) sınıflandırıcıları kullanılmıştır. SVM sınıflandırıcısındaki doğruluk yüzdesini arttırmak için Yerel İkili Örüntü (LBP) ve Yönlü Gradyanlar Histogramı (HOG) öznitelik çıkarım yöntemleri kullanılmıştır.

Derin öğrenme yöntemlerinin en popülerlerinden biri olan CNN ağ çeşidi GoogleNet mimarisi ile eğitilmiştir. Sınıflandırıcılar için günlük hayat akışına uygun olarak belirlenmiş LFW, IMDB ve WIKI veri kümeleri eğitim için, FaceScrub veri kümesi ise test veri kümesi olarak kullanılmıştır. Cinsiyet tespiti için geliştirilen SVM ve CNN sınıflandırıcıları üzerinde gerekli optimizasyon çalışmaları yapılmıştır. Fisher Yüz algoritması ile %61.30, SVM sınıflandırıcısının LBP ve HOG öznitelik çıkarım yöntemleri ile sırasıyla %75.32 ve %80.58, CNN sınıflandırıcısı ile %94.76'lık başarı elde edilmiştir.

ANAHTAR SÖZCÜKLER: Bilgisayarla Görü, Derin Öğrenme, Gerçek Zamanlı Cinsiyet Tespiti, Evrişimsel Sinir Ağları, Destek Vektör Makineleri, Akıllı Reklam

Danışman: Dr. Öğr. Üyesi Emre SÜMER, Başkent Üniversitesi, Bilgisayar Mühendisliği Bölümü.

ABSTRACT

DISTANCE AND GENDER BASED SMART ADVERTISING DISPLAY SYSTEM

Burak KABASAKAL

Baskent University Institute of Science And Engineering

Computer Engineering Department

The vast number of researchers have been focused on pattern recognition and computer vision fields in parallel with recent technological developments over the last two decades. Studies on these subjects have become widespread in recent years. In this thesis, a smart advertisement display system has been developed which feeds real time data from the camera source to get gender information and calculate distance from the camera source.

The developed system has two main stages. Firstly, live broadcast stream, which gets data from the camera source, is handled frame by frame. Then, the face detection part is employed for predicting the gender and distance information. Secondly, detected face images along with the gender labels and distance values are sent to the advertisement display application via the web service and saved into the database. The advertisement system is run in a time counter and analyses the records from the database. The analysis process is based on statistical information such as gender label and distance value to determine advertisements having different levels of detail. Determination of gender information is very important for proper system operation.

For this study, face detection and gender recognition classifiers were implemented. Fisherfaces, Support Vector Machines (SVM) and Convolutional Neural Networks (CNN) classifiers for gender recognition were trained. The SVM classifier with Local Binary Pattern (LBP) and Histogram of Oriented Gradients (HOG) features were used at different times. Besides, various optimization works were performed by changing the parameters. One of the most popular deep learning methods, the CNN network type, was trained with GoogleNet architecture and the optimization was performed depending on the parameters. The LFW, IMDB and WIKI were used as training data sets and the FaceScrub was used as the test data set. Fisherfaces

algorithm yielded an accuracy of 61.30%. When LBP feature extraction method is combined with SVM classifier, the accuracy rate of 75.32% was reached. The HOG feature extraction method with SVM was found to be more successful than LBP and reached an accuracy of 80.58%. Finally, CNN was determined to be the best classifier among all having an accuracy rate of 94.76%.

KEYWORDS: Computer Vision, Deep Learning, Real Time Gender Recognition System, Convolutional Neural Networks, Support Vector Machines, Smart Advertisement

Advisor: Asst. Prof. Dr. Emre SÜMER, Başkent University, Computer Engineering Department.

İÇİNDEKİLER LİSTESİ

Sayfa

ÖZ	i
ABSTRACT	iii
İÇİNDEKİLER LİSTESİ	v
ŞEKİLLER LİSTESİ.....	vi
ÇİZELGELER LİSTESİ.....	viii
SİMGELER VE KISALTMALAR LİSTESİ	ix
1. GİRİŞ	1
1.1. Çalışmanın Konusu, Amacı ve Kapsamı.....	1
1.2. İlgili Literatür ve Benzer Çalışmalar	2
1.2.1 Yüz algılama ile ilgili literatür	2
1.2.2 Cinsiyet tespiti ile ilgili literatür.....	5
1.2.3 Benzer çalışmalar.....	14
1.3. Tez Planı.....	17
2. KULLANILAN YÖNTEMLER	19
2.1. Sistemin Yapısı	19
2.2. Yüz Algılama	24
2.3. Cinsiyet Tespiti.....	28
2.3.1. Fisherfaces (Fisher yüz algoritması).....	28
2.3.2. SVM.....	29
2.3.3. CNN.....	30
2.4. Uzaklık Tespiti	31
3. VERİ KÜMESİ	33
3.1. LFW.....	37
3.2. IMDB	38
3.3. WIKI	40
3.4. FaceScrub.....	41
4. DENEYSEL SONUÇLAR	43
4.1. Geliştirme ve Test Ortam Konfigürasyonları.....	43
4.2. Değerlendirme Sonuçları ve Tartışma.....	49
5. SONUÇLAR	62
KAYNAKLAR LİSTESİ	64

ŞEKİLLER LİSTESİ

Şekil 1.1 Haar-Öznitelikleri [5]	3
Şekil 1.2 HOG Öznitelik Çıkarım Yöntem Sonucu Oluşan Görsel	4
Şekil 1.3 Doğrusal SVM Görseli [15]	6
Şekil 1.4 Çok Boyutlu Doğrusal Olmayan SVM Görseli [16].....	7
Şekil 1.5 LBP Merkez Piksel ile Karşılaştırma Görseli.....	8
Şekil 1.6 LBP Öznitelik Çıkarım Yöntem Sonucu Oluşan Örnek Görseli	8
Şekil 1.7 CNN Genel Mimari Görseli	10
Şekil 1.8 Konvolüsyon Katmanında Filtre Uygulanma Görseli	12
Şekil 1.9 Havuzlama Katmanı Maksimum Piksel Seçim Filtre Görseli	13
Şekil 1.10 Kanban Reklam Sistem Görseli [33]	14
Şekil 1.11 Dijital Reklam Panosuna Ait Görsel [34]	15
Şekil 1.12 İnsan Tespitine Dayalı Video Reklamcılığı İşlem Şeması [35]	16
Şekil 2.1 Sistemin İşlem Akış Şeması	20
Şekil 2.2 Cinsiyet Tespit Uygulamasının Anlık Görseli	21
Şekil 2.3 Reklam Süre Sayaç Görseli.....	23
Şekil 2.4 Web Uygulamasına Ait Görsel.....	24
Şekil 2.5 Imglab Örnek Eğitim XML Yapısı	25
Şekil 2.6 Yüz Algılama Sınıflandırıcısının Işık Değişimindeki Çalışma Görseli....	26
Şekil 2.7 Yüz Algılama Sınıflandırıcısının Birden Fazla Kişi Olmasıyla Çalışma Görseli	26
Şekil 2.8 Yüz Algılama Sınıflandırıcısının Gözlük ve Yüz Engelleyen Cisimle Çalışma Görseli	27
Şekil 2.9 OpenCV ve Dlib Karşılaştırma Görseli.....	27
Şekil 2.10 İnsan Yüzündeki Ön Kıkırdak Mesafe Görseli	31
Şekil 3.1 Veri Kümesi Ön İşlem Şeması	34

Şekil 3.2	Veri Setindeki Görselin Orjinal Hali.....	35
Şekil 3.3	Görselin Ön İşlem Sonrasındaki Hali	35
Şekil 3.4	Veri Kümesi Kontrol Uygulaması	36
Şekil 3.5	Veri Kümesinden Çıkarılan Örnekler	36
Şekil 3.6	LFW Veri Kümesinden Örnek Görüntüler	37
Şekil 3.7	IMDB Veri Kümesinden Örnek Görüntüler	39
Şekil 3.8	WIKI Veri Kümesinden Örnek Görüntüler	41
Şekil 3.9	FaceScrub Veri Kümesinden Örnek Görüntüler	42
Şekil 4.1	wiki.mat'a Ait Görsel	43
Şekil 4.2	imdb.mat'a Ait Görsel	44
Şekil 4.3	Veri Kümesinden Çıkarılan Görüntü Örneği	45
Şekil 4.4	Digits Veri Setine Ait Görsel	47
Şekil 4.5	Deri Öğrenme Modeline Ait Canlı Durum Görseli	48
Şekil 4.6	Eğitilmiş CNN Modellerine Ait Görsel	49
Şekil 4.7	SVM Optimizasyon Uygulamasının Parametre Görseli	51
Şekil 4.8	Web Uygulaması Anlık Görsel-1.....	56
Şekil 4.9	Web Uygulaması Anlık Görsel-2.....	57
Şekil 4.10	Web Uygulaması Anlık Görsel-3.....	57
Şekil 4.11	Web Uygulaması Anlık Görsel-4.....	58
Şekil 4.12	Reklam Öneri Görseli-1	59
Şekil 4.13	Reklam Öneri Görseli-2	60
Şekil 4.14	Reklam Öneri Görseli-3	61

ÇİZELGELER LİSTESİ

Çizelge 2.1 Web Servis Erişim Bilgileri.....	23
Çizelge 3.1 Veri Kümesi Çizelgesi.....	37
Çizelge 3.2 Web Servis Örnek Çalışma Çizelgesi.....	38
Çizelge 4.1 Fisherfaces Farklı Boyutta Başarı Çizelgesi	50
Çizelge 4.2 SVM Optimizasyon Sonrası En Başarılı Sınıflandırıcılar	51
Çizelge 4.3 Eğitilmiş En Yüksek Başarım Yüzdesine Sahip Sınıflandırıcılar	52
Çizelge 4.4 Test Edilmiş Cinsiyet Tespit Sınıflandırıcıları Başarım Oran Çizelgesi.....	53
Çizelge 4.5 Denekler 100 cm Uzaklıktayken	55
Çizelge 4.6 Denekler 150 cm Uzaklıktayken	55
Çizelge 4.7 Reklam Döngüsü Test Sonuçları	56

SİMGELER VE KISALTMALAR LİSTESİ

CNN	Convolutional Neural Networks
CPU	Central Processing Unit
cuDNN	Cuda Deep Neural Network Library
CUDA	Compute Unified Device Architecture
DARPA	The Defense Advanced Research Projects Agency
FPS	Frame Per Second
GPU	Graphics Processing Unit
HOG	Histogram of Oriented Gradients
IARPA	Intelligence Advanced Research Projects Activity
IEEE	Institute of Electrical and Electronics Engineering
IMDB	Internet Movie Database
Java EE	Java Enterprise Edition
LBP	Local Binary Pattern
LDA	Linear Discriminant Analysis
LFW	Labeled Faces in the Wild
LSTM	Long Short Term Memory
LTS	Long Term Support
ODNI	Office of The Director of National Intelligence
PCA	Principal Component Analysis
RBF	Radial Basis Function
RMSE	Root-Mean-Square-Error
RNN	Recurrent Neural Network
WIKI	Wikipedia

1. GİRİŞ

1.1. Çalışmanın Konusu, Amacı ve Kapsamı

Günümüzde artan teknolojik gelişmelere paralel olarak yeni araştırma ve uygulama alanları oluşmaktadır. Bu kapsamda özellikle son yirmi yıldaki teknolojik gelişmelerle birlikte çok sayıda araştırmacı örüntü tanıma ve bilgisayarlı görme alanları üzerine yoğunlaşmıştır. Bu alanlar içinde öne çıkan bazı başlıklar; yüz algılama, yüz tanıma, yüz ifadesi tanımlama, obje algılama ve takibi, yaya tespiti, mimik tanıma ve cinsiyet tespiti olarak sıralanabilir. Popüler olan bu konularda yapılan çalışmalar çoğunlukla insanların günlük hayatlarında doğal şekilde hareket ederken herhangi bir rahatsızlığa sebep olmadan toplanabilen biyometrik verileri kullanmaktadır. Verileri bu şekilde toplayabilmek insanların günlük hayatlarına entegre edilebilecek ürünler geliştirmede büyük bir avantaj sağlamaktadır.

Günümüz dünyasında cinsiyet tespiti; arama sistemleri, güvenlik sistemleri, insan-makine etkileşimli uygulamalar ve cinsiyete bağlı reklamcılık gibi birçok alanda kullanılmaktadır. Geçmişte sadece televizyon, dergi ve gazete gibi belirli medya organlarında yer alan reklamlar zamanla web ortamına taşınmıştır. Günümüzde ise, günlük hayatın içinde elektronik ekranlarla her alanda reklam yapabilmek mümkündür. Örneğin, reklam alanında çalışan bir firma ABD’de bulunan bir akaryakıt şirketinin tüm şubeleri için geliştirdiği akıllı dijital ekran sayesinde cinsiyet ve yaş tabanlı reklam içerik hizmeti sunmaktadır [1]. Böylelikle, dijital ekran tarafından tespit edilen kişilerin cinsiyet ve yaşlarına uygun reklamlar gösterilebilmektedir. Aynı şekilde ülkemizde faaliyet gösteren bir bankanın şubelerinin vitrinlerinde bulunan akıllı dijital ekranlar sayesinde yaşlarına ve cinsiyetlerine uygun kişiye özel kampanyalar sunulmaktadır [2].

Yukarıda verilmiş örneklerden de anlaşılabileceği üzere, insan yüzleri üzerinden cinsiyet tespiti ile ilgili kazanılan deneyimlerle birlikte reklam alanında oldukça ileriye gidilmiş ve kitlesel reklamcılıktan kişiye özel reklam çalışmalarına geçilmiştir. Böylelikle statik resimlerle yapılan, kısıtlı miktarda veri sunulabilen ve tüketicilerin ilgisini çekmeyen reklamcılık anlayışına yeni bir boyut kazandırılmıştır.


Tez kapsamında yapılan çalışmada kamera tarafından görüntülenen insanların cinsiyet ve kameraya olan uzaklıkları üzerinden reklam üreten akıllı bir sistem geliştirilmiştir. Sistem; algıladığı insan yüzlerinden cinsiyet tespiti yaptıktan sonra, baskın olan cinsiyetin ortalama uzaklık bilgisine göre reklam içeriğinde değişiklik yapabilmektedir. Buna ek olarak, kameradan alınıp işlenen görüntüler üzerinde cinsiyet etiket ve uzaklık bilgileri de saklanabilmektedir.

1.2. İlgili Literatür ve Benzer Çalışmalar

1.2.1 Yüz algılama ile ilgili literatür

Yüz algılama, son yirmi yılda popüler hale gelmiş bilgisayarla görü alanlarından biridir. Gelişen teknolojik gelişmeler ve bu alanda artan araştırmalar sonucunda günlük hayatımızda yer alan bir konu haline gelmiştir. Kullandığımız cep telefonlarındaki birçok uygulamada, güvenlik sistemlerinde, istatistiksel bilgi toplayan sistemlerde, reklam sistemlerinde oldukça aktif olarak kullanılmaktadır.

Yüz algılama metotları temel olarak iki ana başlık altında incelenebilir. Bunlar öznitelik tabanlı ve görünüm tabanlı yaklaşımlardır. Öznitelik tabanlı yaklaşımda, görüntüden çeşitli öznitelikler çıkarılır ve yüz algılama işlemi bu öznitelikler üzerinden yapılmaktadır. Kenar veya ten rengi bilgisi ve öznitelik çıkarım tabanlı geliştirilmiş özel metotlar yüz geometrisindeki bilgileri kullanmaktadır. Görünüm bazlı yaklaşımda ise, tüm görüntü üzerinden yapılan belirli ön işlem adımlarıyla birlikte yüz algılama işlemi bu girdi üzerinden yapılmaktadır [3]. Buna örnek olarak 2001 yılında geliştirilmiş olan Viola ve Jones [4] algoritması yüz algılama konusuna farklı bir bakış açısı kazandırmıştır. Algoritma, görüntüde belirlenen nesnenin yüz olup olmadığını algılamak için insanların yüzlerinde genel olarak aynı olan özelliklere bakmaktadır. Bu işlem için belirlenmiş ve Şekil 1.1'de gösterilmiş pencereler tüm resim boyunca gezdirilerek nesne tarama işlemi gerçekleştirilir.



Şekil 1.1 Haar-Öznitelikleri [5]

Bu alt pencereler, Haar-benzeri öznitelikler olarak da bilinmektedir. Görüntünün üzerinde Haar- benzeri öznitelik pencerelerinin gezdirilmesi oldukça zahmetlidir. Bu nedenle; Viola ve Jones, AdaBoost algortimasını kullanarak en iyi Haar-öznitelikleri seçebilen, seçtiği öznitelikleri kullanabilen ve bu işlemi hızlı şekilde gerçekleştirebilen bir sınıflandırıcı eğitmişlerdir.

Yüz algılama işleminde kullanılan önemli öznitelik çıkarım yöntemlerinden birisi de HOG' dur. Bu yöntem yerel bölgelere bölünmüş histogramları kullanarak hesaplanan gradyanlar ve yönelimlerinin sayısını içermekte olup gradyanların hesaplanmasında piksel parlaklık bilgisini kullanmaktadır [6], [7]. HOG kendi içinde farklı yerel alanları birbirinden ayırdığından nesne tanıma uygulamaları için ideal bir yaklaşımdır. Dalal ve Triggs geliştirdikleri algoritma ile HOG'un insan tanıma çalışmalarında kullanılabileceğini ortaya koymuşlardır [8], [9]. HOG'un sıkça tercih edilmesinin nedeni hızlı ve başarılı sonuçlar verebilmesi ve geometrik değişkenlerden etkilenmemesidir [8]. HOG yönteminin öznitelik çıkarımındaki işlem basamakları şu şekilde sıralanmaktadır:

- Görüntünün gradyan büyüklük ve yönlerin hesaplanması,
- Yerel gruplara ayrılmış her bir kesit için histogram hesaplanması,
- Yerel gruplanmış histogramların bloklar halinde birbirleri ile normalize edilmesi.


HOG'un hesaplanması ile ilgili olarak yatay ve dikey değişimleri ortaya çıkaran çeşitli filtreler kullanılmaktadır [10]. Bunlardan en sık kullanılanı Sobel filtresi'dir. Yatay ve dikey gradyan büyüklükleri Denklem 1.1'deki gibi hesaplanır.

$$\begin{aligned} g_x(x,y) &= i(x+1,y) - i(x-1,y) \\ g_y(x,y) &= i(x,y+1) - i(x,y-1) \end{aligned} \quad (1.1)$$

Denklem 1.1'de kullanılmış olan $i(x,y)$ imgenin (x,y) noktasındaki parlaklık değerini göstermekte olup $g_x(x,y)$ ve $g_y(x,y)$ yatay ve dikey yöndeki gradyan büyüklükleridir. Toplam gradyan büyüklüğü ' m ', yönü ise ' θ ' ile gösterilmiş olup hesaplamalar Denklem 1.2'de belirtilmiştir [10].

$$\begin{aligned} m(x,y) &= \sqrt{g_x(x,y)^2 + g_y(x,y)^2} \\ \theta(x,y) &= \arctan \frac{g_x(x,y)}{g_y(x,y)} \end{aligned} \quad (1.2)$$

Şekil 1.2'de HOG öznitelik çıkarım yönteminin örneklendiği bir durum verilmiştir. Buna göre, orijinal görüntü belirli sayıdaki yerel bölgelere bölünmüş olup, her bir yerel bölge için elde edilen yönelim bilgisi sağdaki resim üzerinde görülmektedir.



Şekil 1.2 HOG Öznitelik Çıkarım Yöntem Sonucu Oluşan Görsel

1.2.2 Cinsiyet tespiti ile ilgili literatür

Cinsiyet tespiti, gelişen araştırma ve çalışmalarla birlikte insanların günlük hayatına yerleşmiş en önemli bilgisayarla görü problemlerinden birisidir. Cinsiyet tespitinin kullanıldığı birçok uygulama alanı vardır. İnsanların cep telefonlarındaki uygulamalarda, güvenlik amaçlı geliştirilen arama ve analiz sistemlerinde, istatistiksel bilgi toplayan çalışmalarda, cinsiyet bazlı reklam uygulamalarında sıkça kullanılmaktadır.


1991 yılında Eigenfaces algoritması Pentland ve Turk tarafından yüz tanıma algoritması olarak duyurulmuştur. Eigenfaces algoritması temelde PCA yaklaşımını benimsemektedir. Temel problem $p \times q$ boyutlarına sahip olan bir görüntü üzerinde işlem yapmak için “p” ve “q” değerlerinin çarpımı boyutunda bir vektör oluşturmak gerekmektedir. Bir örnekle açıklanacak olursa; 100×100 boyutundaki bir görüntü için 10.000 boyutlu bir görüntü uzayı oluşturulmalıdır. Eigenfaces algoritmasının kullandığı PCA yöntemi, ana bileşenler olarak adlandırılmış olan verilerdeki en büyük varyansı içeren yeni bir boyut bulmayı hedeflemektedir. Bu hedef doğrultusunda yaptığı işlem sonucunda sadece anlamlı bilgileri içeren yeni vektör uzayına indirgenmiş veri elde edilmiş olmaktadır. Böylelikle bilgi karmaşıklığının azalmasını, tanımadaki başarı oranının artmasını ve çalıştığı sürenin azaltılması amaçlanmaktadır. Boyut indirgeme işlemi görüntülere ait bilgilerin en az şekilde kaybedilmesini sağlayacak şekilde yapılmaktadır. Düşük varyans değerlerine sahip verilerin katkısının düşük olması boyut azaltımı sırasında veri kaybını büyük ölçüde engellemektedir [11], [12].

Fisher yüz algoritması ise 1997 yılında Belhumeur, Hespanha ve Kriegman tarafından duyurulmuş, sınıflandırma tabanlı tanımaya olanak sağlayan diğer bir yöntemdir. Fisher yüz algoritması, Eigenface algoritmasının gelişmiş şeklidir. Boyut azaltım için LDA yaklaşımını benimsemiştir. LDA yaklaşımı, sınıflar arasındaki dağılımın maksimize edilmesini, sınıf içi dağılımın ise minimize edilmesini hedeflemektedir. Böylelikle aynı sınıfların birlikte sıkı bir şekilde kümelenmesi sağlanmış olmaktadır [12].

Cinsiyet tespit işleminde kullanılan önemli yöntemlerden birisi de SVM’ dir. SVM, 1995 yılında Vladimir Vapnik, Bernhard Boser ve Isabelle Guyon tarafından


geliştirilmiş olan istatistiksel öğrenme teorisini benimsemiş bir sınıflandırma metodudur. SVM'in çalışma prensibindeki temel amaç, iki farklı sınıftan oluşan veri kümelerini birbirinden en uygun şekilde ayırmak için en uygun fonksiyonu bulmaktır [13], [14].

SVM, veri kümesinin doğrusal olarak ayrılıp ayrılamaması durumuna göre doğrusal veya doğrusal olmayan SVM şeklinde ikiye ayrılmaktadır. Doğrusal SVM, farklı sınıfa ait kümelerin eğitim verisiyle elde edilmiş doğrusal bir karar fonksiyonu sayesinde ayrılabilmesidir. Bu doğruya karar doğrusu adı verilmektedir. Karar doğrusunun görmediği veriler üzerinde başarılı bir şekilde sınıflandırma işlemi yapılabilmesi için kendisine en yakın noktalar arasındaki uzaklığı maksimum yaparak ayırt edici düzlem bulmayı amaçlar [3]. Şekil 1.3' te SVM tarafından doğrusal olarak ayrılabilmiş örnek bir görsel bulunmaktadır. Görselde iki ayrı kümeyi birbirinden ayıran H fonksiyonları verilmektedir. Bu görselde sunulan H2 ve H3 ayırt edici fonksiyonlardır. Ancak H3 fonksiyonu noktalar arası uzaklığı maksimum yaparak ayırdığından en iyi ayırt edici fonksiyondur.



Şekil 1.3 Doğrusal SVM Görseli [15]

Doğrusal olmayan SVM türünde ise, farklı kümeleri birbirinden ayırma işlemi için belli bir karar doğrusu çizilememektedir. Veri kümelerinin doğrusal olarak ayrılamadığı bu durumda hiper-düzlem üzerinde sınıflandırma işlemi yapmak için daha yüksek boyuttaki bir uzaya geçilmekte ve veri kümelerinin hiper-düzlemle birbirlerinden ayrılması sağlanmaktadır. Şekil 1.4' te çok boyutlu sistem üzerinde ayırma işlemine bir örnek verilmiştir. Bu durumlarda Polinomiyal, Sigmoid ve Radyal tabanlı çekirdek fonksiyonları sayesinde sınıflandırma yapılabilir.




Şekil 1.4 Çok Boyutlu Doğrusal Olmayan SVM Görseli [16]

SVM ile beraber kullanılan en önemli öznitelik çıkarım yöntemlerinden birisi HOG olup HOG ile ilgili detaylara Bölüm 1.2.1’de yer verilmiştir. SVM kullanımında yer alan bir diğer önemli öznitelik çıkarım yöntemi ise LBP’ dir. LBP gri seviyeye çevrilmiş bir görüntüde NxN boyutuna göre belirlenmiş merkez pikselin komşu piksel değerleri ile karşılaştırılması sonucu elde edilmektedir. Belirlenmiş boyut içindeki komşu piksel değerleri merkez pikselden büyük veya eşitse “1”, küçük ise “0” değeri atanmaktadır. Denklem 1.3’te gösterildiği gibi atama yapılmaktadır.

$$u(y) = \begin{cases} 1 & y \geq 0 \\ 0 & y < 0 \end{cases} \quad (1.3)$$


Denklem 1.3’te yapılan işlem sonucunda komşuluk bölgesi için LBP kodu oluşturulur. Örneğin 3x3’lük bir bölge için 8 bitlik kod oluşmasına ait formül Denklem 1.4’te ve örnek görsel ise Şekil 1.5’ te gösterilmiştir. Buradaki x_c merkez pikseli, x_p komşuluktaki p-inci değeri, R komşuların merkeze uzaklığını ve P komşu piksel sayısını ifade etmektedir [17], [18].

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p \quad (1.4)$$



Şekil 1.5 LBP Merkez Piksel ile Karşılaştırma Görseli

LBP, daha önceden belirlenmiş boyutlardaki bloklara ayrılmış resmin her bir bloğu için yerel histogram değerleri çıkarmaktadır. Çıkardığı değerleri uç uca bağlanarak histogram vektörü elde edilmektedir. Şekil 1.6'da LBP öznelik çıkarım yöntemi ile elde edilen örnek bir resim görülmektedir.



Şekil 1.6 LBP Öznelik Çıkarım Yöntem Sonucu Oluşan Örnek Görseli

Cinsiyet tespitinde kullanılan önemli ve güncel yaklaşımlardan birisi de derin öğrenmedir. Derin öğrenme ilk olarak 2012 yılında büyük bir etki yaratarak bilim dünyasına girmiştir. Nesne algılama alanında yapılan ImageNet yarışmasında derin öğrenmenin en çok kullanılan çeşidi CNN, Krizhevsky ve Sutskever tarafından literatüre kazandırılmıştır [19].


Derin öğrenme ile ilgili yapılan çalışmalar geçmişten beri devam etse de kullanımı en çok son yıllarda artmıştır. Buna sebep olarak ihtiyaç duyulan kaynakların daha kolay sağlanabilmesi, GPU'ların hesaplama işlemlerinde kullanılmasıyla birlikte paralel işlemlerin yapılabilmesi ve günümüz dünyasında bilgisayarların oldukça fazla kullanılmasına bağlı olarak dijitalleşmenin artması sıralanabilir. Dijitalleşen dünyada artan veri miktarı Büyük Veri (Big Data) kavramıyla ilgilenen bir alan ortaya çıkarmış ve bu alan makine öğrenimini kolay hale getirmiştir.

Özellikle GPU, Büyük Veri konusu ve bilgisayar kaynaklarının gelişimleri farklı Derin Öğrenme modellerinin tasarlanmasına olanak sağlanmıştır. Sinir ağlarındaki gizli katmanların sunulması bellek hafıza kullanımını ve yapılan işlem hesabını arttırmaktadır. Gizli katman sayısının arttırılabilir olmasıyla derinleşen ağ büyük bellekli çalışma ortamlarına ihtiyaç duymaktadır. Örneğin, Krizhevsky ve Sutskever'in kazandığı ImageNet yarışmasında 1.2 milyonluk bir veri kümesi kullanılmıştır. Ağa gelen girdi görüntüsü 220x220x3 boyutunda ise 220x220x3x 1.2 milyon baytlık bellek hafızasına ihtiyaç duyulmaktadır [20].

Konuyla ilgili artan araştırma ve gelişmeler doğrultusunda büyük şirketler için derin öğrenme oldukça önem arz etmektedir. Örneğin DARPA isimli Amerikan ordusuna yeni teknolojik ürünler katmakla sorumlu kurum, 2015 yılında derin öğrenmedeki başarılı gidişi fark edip görüntü analizinde kullanımını zorunlu kılmıştır. Google, Deepmind Firmasını satın almış ve resim tanıma, konuşma tanıma gibi akademik yarışmalara katılarak makaleler yayınlamıştır. Kısa süre içinde resim arama, Android konuşma tanıma, StreetView, reklam yerleştirme uygulamaları gibi 50 üründe derin öğrenme yöntemini kullanmıştır [21]. Google Deepmind firması AlphaGo isimli bir oyun geliştirmiştir. Bu oyun Japonya'da "İgo", Çin'de "WeiQi", Kore'de "Baduk" ve Avrupa'da "Go" olarak adlandırılmıştır. CNN tabanlı geliştirilmiş olan AlphaGo oyunu profesyonel bir oyuncuyu yenmiş ve bu bir oyuncuyu yenen ilk uygulama olmuştur [22]. Microsoft yapay zeka, doğal dil işleme ve 100 dili destekleyen klavye uygulamasına sahip SwiftKey'i satın almıştır. Apple yapay zekâ uygulaması olan Siri üzerinde iyileştirme ve geliştirmeleri ilerletmek için Novauris şirketini bünyesine katmıştır. Bu tarz örnekler derin öğrenme konusunda yapılan gelişmelerin öncelikli olarak takip edildiğini kanıtlamaktadır.

Derin öğrenme, yapısı gereği verilerin birden fazla öznitelik seviyesinin veya temsillerinin öğrenilmesini baz almaktadır. Temsil edilen veriden öğrenme hedeflenmektedir. Burada temsil ile kastedilmeye çalışılan, her piksel başına düşen kenar kümeleri, değer vektörü veya özel şekillerdir. En iyi temsil yeteneğine sahip öznitelik çıkarım işlemi için kullanılan belirli algoritmalar bulunmaktadır [23].

Derin öğrenme kendi içinde CNN (Evrişimsel Sinir Ağları), RNN (Tekrarlayan Sinir Ağları), LSTM (Uzun-Kısa Vadeli Hafıza Ağları) gibi mimariler içermektedir. Tez kapsamında kullanılan derin öğrenme modelinde CNN mimarisi tercih edilmiştir. Şekil 1.7’de 1988 yılında LeCun tarafından ortaya atılan ilk CNN ağının genel mimarisine ait görsel bulunmaktadır [24] .




Şekil 1.7 CNN Genel Mimari Görseli

CNN, Şekil 1.7’deki görselde de görülebileceği gibi bir veya birden fazla konvolüsyon ve havuzlama katmanı içerir. Bir sonraki aşamasında ise tam bağlı katman ve son olarak sınıflandırma katmanları bulunur [25], [26]. CNN temel yapı olarak ardışık yerleştirilmiş katmanlardan oluşur ve son kısımda sınıflandırma işlemi gerçekleştirilir. Çalışma prensibi olarak her katman giriş verisini aldıktan sonra eğitim sürecini gerçekleştirir ve temelde görüntü sınıflandırma üzerine yoğunlaşmaktadır [26]. En sonunda bir final çıktısı üretilir ve bu çıktı doğru sonuç ile karşılaştırma yapmak için kullanılmaktadır. Bu karşılaştırmada üretilen ve istenilen sonuç değerlerinin arasındaki fark kadar hata oluşmaktadır. Karşılaştırmayla ortaya çıkan bu hatanın bütün ağırlıklara aktarılması gerekmektedir ve bu işlem için yayılım algoritması kullanılmaktadır. Belirlenmiş olan bu hata her iterasyonda ağırlıkların tekrar güncellenmesiyle azaltılmaktadır [20].

CNN, öncelikli ve temel olarak sınıflandırma üzerine yoğunlaşmıştır. Ancak son yıllarda diğer alanlarda da kullanılmaktadır. LeCun ve Bengio piksellerden kenar kombinasyonlarını oluşturarak motiflere dönüştüren, dönüşümü tamamlanmış motiflerin bir araya getirilerek birleşmesinden nesnelere ait parçalara ve son olarak parçalardan nesnelerin tümünü gerçekleştiren bir çalışma yapmıştır [20]. Grefenstette, Blunsom ve Hermann anlamsal ayrışma ile ilgili çalışmasında [27], Shen, He, Gao, Deng ve Mesnil web aramasında CNN kullanarak semantik gösterimleri öğrenme yani arama sorgusunu elde etme [28], Kalchbrenner, Grefenstette ve Blunsom ise cümle modelleme çalışmasında CNN kullanmıştır [29], [30].

CNN birçok katmandan oluşmaktadır. Giriş katmanı, ilk verinin alınarak ham bir şekilde ağa verildiği katmandır. Bu katmana gelen veri boyutunun yüksek olması yüksek bellek ihtiyacına ve uzun eğitim süresine sebep olmakla birlikte genelde ağ başarısını arttırmaktadır. Ayrıca düşük boyuttaki veride ağ derinliği azalacağından performans düşüklüğü gözlenme ihtimali yüksektir.


Konvolüsyon katmanı CNN'in en temel katmanıdır. Bünyesinde barındırdığı filtrelerin bir önceki katmanın ilettiği görüntü üzerinde dolaştırılmasına dayanmaktadır. Filtrelerin katsayıları eğitimdeki her öğrenmeyle değişmektedir. Böylece ağ önem taşıyan bölgeleri tespit etmiş olmaktadır. Ayrıca filtre katsayılarındaki değişimler model tasarımcıları tarafından değiştirilebilmektedir. Filtrenin görüntü üzerine uygulanması Şekil 1.8'de gösterilmiştir. Görselde görüldüğü üzere giriş görüntüsü renk kanallarıyla birlikte 5x5x3 boyutundadır. Her bir kanal görselde belirtilen filtre örneğindeki gibi işleme sokulmakta ve ortaya çıkan sonuçlar aktivasyon haritasına eklenmektedir.



Şekil 1.8 Konvolüsyon Katmanında Filtre Uygulanma Görseli

Havuzlama katmanı, kendisinden sonra gelecek olan konvolüsyon katmanına verilecek girdi için boyut azaltmayı amaçlamaktadır. Bu katmanda yapılan boyut azaltması bilgi kaybına sebep olmaktadır. Ancak buradaki bilgi kaybı sistemin verileri ezberlemesinin önüne geçmektedir. Havuzlama katmanı da filtrelerle görüntü üzerinde çalışma yapmaktadır. Görüntü üzerinde işlem yaparken tek tek ilerlemek yerine belirlenmiş adımlara göre kayarak çalışır. Çerçevenin içine aldığı veriler içinden maksimum olan değeri saklamaktadır. Bu sebeple maksimum havuzlama katmanı olarak da adlandırılmaktadır. Ek olarak, filtre maksimum piksel

değeri yerine ortalama değer üzerinden de çalışabilmektedir. Havuzlama katmanı zorunlu olmayan bir katman olduğu için bazı mimarilerde kullanılmamaktadır. Şekil 1.9'da havuzlama katmanında filtre içinde kalan bilgiler üzerinden maksimum piksel değeri seçimine dair bir örnek verilmiştir. Örnekte 2x2'lik şekilde gezmekte olan filtre iki adım kayarak çalışmaktadır.



Şekil 1.9 Havuzlama Katmanı Maksimum Piksel Seçim Filtre Görseli

Tam bağlantılı katman, peş peşe gelen konvolüsyon ve havuzlama katmanından sonra gelmektedir. Kendisinden önce yer alan katmanların tüm alanlara bağlantısı vardır. Yani tam bağlantılı katmana ait bütün girişler ve çıkışlar yani nöronlar kendinden sonra gelen nöronla bağlı ve her bir nörona atanmış ağırlık değerleri içermektedir. Bu sebeple tam bağlantılı katman olarak bilinmektedir.

DropOut katmanı, büyük verilerle yapılan eğitim işlemlerinde ağız ezberleme durumunun önüne geçmek için kullanılmaktadır. Bunu, katman içinde birbirine sıkça bağlanmış nöron düğümlerinden bazılarını kaldırarak gerçekleştirir.

Sınıflandırma katmanında sınıflandırma işlemi yapılır. Bu katman tam bağlantılı katmandan sonra gelir. Bu katmandan sonuç olarak eğitim için belirlenmiş etiket sayısı kadar sonuç üretilmektedir. Örneğin cinsiyet tespit işlemi için erkek ve kadın olmak üzere iki etiket bulunmaktadır ve sınıflandırma katmanı iki çıkış değeri üretir [31] [32].

1.2.3 Benzer çalışmalar

Literatürde ilgi ölçmeye dayalı reklam gösterimi ile ilgili bazı çalışmalar bulunmaktadır. Bunlardan Cheng ve arkadaşları 2013 yılında yaptıkları bir çalışmada, belirli uzaklıktan itibaren algılanan yüzlerin ekrana olan uzaklığına göre yazı boyutunu değiştirerek kullanıcıya reklam sunan bir sistem geliştirmişlerdir [33]. Kameradan alınan fotoğraf sisteme verildikten sonra sınıflandırıcıya girmeden bazı ön işlemlerden geçmektedir. Öncelikle deri algılama işlemi, daha sonra yüz bölgesini belirleme ve son olarak da yüzdeki göz ve ağız bölgelerini belirleme işlemleri uygulanmaktadır. Eğitilmiş oldukları AdaBoost sınıflandırıcısı ile yüz algılama işlemi yapılmaktadır. Belirlenmiş bir yüz varsa piksel büyüklüğünün değerine göre uzaklık tespiti gerçekleştirilmektedir. Bu işlem için piksel büyüklüklerine karşılık gelen uzaklıklar önceden belirlenmiştir. Sistemin arayüzü iki parçaya bölünmüş, sol tarafta reklama ilgi duyan insan fotoğrafı sağ tarafta ise reklama ait bilgiler bulunmaktadır. Sisteme ait görsel Şekil 1.10'da gösterilmektedir.



Şekil 1.10 Kanban Reklam Sistem Görseli [33]

2009 yılında Chen ve Lin yaptıkları çalışmada, dijital ekrana bakan insan sayısını sayan bir sistem geliştirmişlerdir [34]. Böylelikle gösterilen reklam kullanılarak, ürünle ilgili veri elde edilmesi amaçlanmıştır. Sistem öncelikle yüz algılama yaparak reklamlarla ilgilenenleri belirlemektedir. Yüze ait alanı elde etmek ve hatalı yüzleri elemek için filtre kullanarak ilgi alanları elde edilmiştir. Sonrasında bu alanlar


üzerinden öznitelik çıkarımı yapılmıştır. Güvenilir bir insan sayımı yapabilmek ve eksiklikleri giderebilmek için insanların gövdesinden de öznitelik çıkarılmıştır. Sistemde AdaBoost tabanlı çevrimiçi eğitilebilir bir sınıflandırıcı kullanılmıştır. Bu sınıflandırıcıda, mimik değişimlerinde aynı kişiyi bir kez daha saymamak için oluşturulmuş şablonlar kullanılarak eğitim süreci gerçekleştirilmiştir. Geliştirilen sistem ile sabit bir kameranın gerçek zamanlı video akışlarında tekrarları saymadan dijital bir ekranı izleyen kişi sayısını sayabilen yeni bir görüntüleme sayacı sunulmuştur. Sistemin çalışma anına ait görsel Şekil 1.11’de gösterilmiştir.



Şekil 1.11 Dijital Reklam Panosuna Ait Görsel [34]

Zhang ve arkadaşları 2016 yılında yaptıkları çalışmayla insan tespitiye dayalı video reklamcılığı için yeni bir yöntem sunmuşlardır [35]. Bu bağlamda, video akışı içinde içerikle ilgili reklamları içeriğe yerleştirmeyi amaçlayan bir çalışma gerçekleştirmişlerdir. Özellikle içerikle alakalı reklamları destekleyebilmek için, videodaki insanlar tespit edilmiş ve tespit edilen insanlara göre reklam modelleri kullanılmıştır. CNN tabanlı geliştirilen cinsiyet tespit sınıflandırıcısı ile insan giyim reklamcılığı yapılmaktadır. Sistem genel işleyiş olarak, öncelikle insan objesini tespit etmeyi amaçlar. Tespit edilen insan iki parçaya ayrılır. Yüz görüntüsü üzerinden yüz algılaması yapılmakta olup, kalan vücut bilgisi de kendi içinde iki farklı işleme sokulmaktadır. Bunlar, vücut bölümlerinin algılanması ve vücut görüntüsünün arka plandan ayrılmasıdır. El, ayak, kol gibi parçaların algılanmasından sonra öznitelik çıkarımı yapılmakta ve her vücut parçasına ait öznitelik verisi arka plandan

ayrıştırılmaktadır. Sonrasında ise öznitelik eşleşme işleminin hesaplanması sonucu en alakalı reklam belirlenmektedir. Sistemin işleyişine ait görsel Şekil 1.12’de sunulmaktadır.



Şekil 1.12 İnsan Tespitine Dayalı Video Reklamcılığı İşlem Şeması [35]

Araştırmada yüz görüntüsü belirlenmiş veri üzerinden yapılan cinsiyet tespiti sonrasında cinsiyet etiketine göre kıyafet reklamı sunulmaktadır. Cinsiyet tespit işlemi için, altı katman derinlikte bir CNN derin öğrenme sınıflandırıcısı kullanılmıştır. Veri kümesi olarak LFW [36]’den yararlanılmıştır. Sınıflandırıcı, beş katmanlı çapraz doğrulama sonucunda %97.45’lik başarımla ulaşılmıştır.

Levi ve Hassner 2015 yılında derin öğrenme tabanlı CNN ağ çeşidini kullanan cinsiyet ve yaş tespiti yapan bir çalışma yapmışlardır [25]. Bu çalışmada, CNN ile cinsiyet ve yaş tespitinde performans ve başarımlarında geliştirme gösterildiği belirtilmiştir. Sundukları mimari model, kısıtlı sayıdaki veriyle bile yüksek başarımla oranın erişilebileceğini göstermiştir. Geliştirilmiş olan cinsiyet ve yaş tespit sınıflandırıcı modelleri ve modellere ait dosyalar kullanım ve geliştirme amaçlı olarak paylaşılmıştır. Böylece geliştirdikleri model birçok uygulama ve araştırmada kullanılabilir [37], [38]. Bu tez kapsamında geliştirilmiş olan cinsiyet tespit sınıflandırıcıları Levi ve Hassner’in modelleriyle de karşılaştırılmıştır. Derin öğrenme yöntemiyle eğitilmiş bir model tekrar eğitime sokulabilmekte ve böylelikle model üzerinde geliştirme yapılmasına olanak sağlamaktadır.

Gerçekleştirilen bu tez çalışması kapsamında literatürdeki çalışmalardan farklı olarak, gerçek zamanlı çalışan bütünleşik bir sistem önerisi sunulmuştur. Sistem işlediği görüntüler üzerinde algıladığı yüz veya yüzlerin hem cinsiyetlerini hem de uzaklık bilgilerini kullanmaktadır. Ayrıca çalışma anında çoklu insan yüzleri üzerinde yaptığı tespitler doğrultusunda kullanıcının ilgisine göre içerik üretebilen bir sistem önerisi sunulmuştur.

1.3. Tez Planı

Uzaklık ve Cinsiyet Tabanlı Akıllı Reklam Görüntüleme Sistemi'ni anlatan bu tezin ilk bölümünde (Bölüm 1.1) çalışmanın konusu, amacı ve kapsamı açıklanmıştır. Bölüm 1.2'de tezde kullanılmış olan literatür bilgilerine ve yapılan benzer çalışmalara yer verilmiştir.

Tezin ikinci bölümde, önerilen sistemin yapısına dair geliştirilen yöntemden ve adımlarından bahsedilmiştir. Öncelikle ortaya konan sistemin çalışmasına ve içerdiği modüllere ait bilgilere yer verilmiştir (Bölüm 2.1). Daha sonra sistemin içerdiği alt modüllerin incelenmesine geçilmiş ve Bölüm 2.2'de yüz algılama işlemi için tekrar eğitime sokulmuş sınıflandırıcının eğitime ait detaylara yer verilmiştir. Bölüm 2.3 başlığına ait alt modüllerde sistemin yapısı için büyük önem arz eden ve farklı metotlarla ele alınmış olan cinsiyet tespit sınıflandırıcılarına ait genel bilgiler sunulmuştur. Bölüm 2.3.1'de Fisher yüz algoritmasının tez kapsamında eğitilen cinsiyet tespit sınıflandırıcısına ait detaylı bilgilere yer verilmiştir. Bölüm 2.3.2'de, SVM sınıflandırıcısının çekirdek seçim ve çekirdeğe bağlı optimizasyonu için geliştirilmiş olan uygulama hakkında bilgilere ve tez kapsamında geliştirilmiş olan sınıflandırıcının kullandığı öznitelik çıkarım yöntemlerine ait bilgiler sunulmuştur. Bölüm 2.3.3'te derin öğrenme tabanlı sınıflandırma metotlarından CNN ağ çeşidi kullanılarak eğitilen cinsiyet tespit sınıflandırıcısının mimari detayları, dosya bilgileri ve geleneksel makine öğrenme tekniklerinden farklılıkları ortaya konmuştur. Bölüm 2.4'te yüz algılaması ve cinsiyet tespiti yapılmış olan görüntünün kameraya olan uzaklığının hesaplanmasına dair bilgilere yer verilmiştir.

Tezin üçüncü bölümünde veri kümesi kavramının öneminden ve kullanımından bahsedilmiş, geliştirilen sistemin başarı oranının yüksek ve doğru olması amacıyla

geliştirilen veri seti değerlendirme uygulamasına dair bilgilere yer verilmiştir. İlgili kısımda ayrıca sistemin eğitim ve test aşamalarında kullanılmış olan LFW (Bölüm 3.1), IMDB (Bölüm 3.2), WIKI (Bölüm 3.3) ve FaceScrub (Bölüm 3.4) veri setlerinin içerdiği verilere ait istatistiksel bilgiler, verilerin sisteme eklenme ve çıkarılma yöntemlerine dair bilgiler sunulmuştur.


Tezin dördüncü bölümünde sistemin geliştirme ve değerlendirme basamakları üzerinde durulmuştur. Bölüm 4.1’de önerilen yöntemin geliştirilmesinin yapıldığı donanım, kullanılan kütüphaneler ve geliştirilen yan yazılımlara ait bilgiler sunulmuştur. Bölüm 4.2’de ise sistemin genel başarımı hakkındaki değerlendirmelere, geliştirilmiş olan cinsiyet tespit sınıflandırıcılarının karşılaştırılmasına ait istatistiksel ve görsel verilere yer verilmiştir.

Tezin son bölümünde, elde edilen sonuçlara ve yapılan çalışmalardan yola çıkılarak gerçekleştirilebilecek yeni çalışmalara yönelik bilgilere yer verilmiştir.

2. KULLANILAN YÖNTEMLER


2.1. Sistemin Yapısı

Tez çalışmasında geliştirilen akıllı reklam görüntüleme sistemi, belirlenmiş süre içinde algıladığı insan yüzlerinin cinsiyetlerine ve uzaklıklarına bağlı olarak ilgili reklamları farklı detay seviyesinde üretebilmektedir. Sistem kendi içinde birbirinden bağımsız iki ayrı parçadan oluşmaktadır. Bu bağımsız uygulamalar birbirlerinden ayrı olarak çalışabilen ve birbirleriyle haberleşmesiyle bütünleşen parçalardır. Bu parçalar, Qt tabanlı geliştirilmiş masaüstü uygulaması ve Java Enterprise Edition (EE) çatısı altında geliştirilmiş bir web uygulamasıdır. Sistemin çalışmasına ait senaryo şu şekildedir: Qt tabanlı istemci uygulamanın bünyesinde barındırdığı yüz algılama, cinsiyet tespiti ve uzaklık tespiti modüllerinden topladığı verileri Java EE tabanlı sunucu uygulamasının web servisine gönderir. Gelen veriler, sunucu tabanlı uygulamanın kullandığı veri tabanında depolanır. Veri depolama işlemi belirlenmiş reklam süre sayacı sıfırlanana kadar sürmektedir. Sayaç sıfırlandığında sunucu uygulaması veri tabanında depoladığı veriler üzerinden baskın olan cinsiyet etiketini ve baskın cinsiyet etiketine ait ortalama uzaklık verisine göre kullanıcılara görsel reklam sunmaktadır. Şekil 2.1’de sistemin genel görünüm ve işleyişine ait akış şeması yer almaktadır.



Şekil 2.1 Sistemin İşlem Akış Şeması

Sistemin Qt tabanlı istemci birimi, gerçek zamana yakın olarak işlediği görüntülerden elde ettiği sonuçları gösteren bir uygulamadır. Bu uygulama işlediği görüntülerde algıladığı yüzlerin cinsiyetini ve uzaklığını tespit etmektedir. Algılanmış yüz kesitleri cinsiyet etiketine göre kadınsa kırmızı, erkekse mavi kare içinde gösterilmektedir. Şekil 2.2’de uygulamanın çalışma zamanındaki görüntüsüne ait görsel yer almaktadır.



Şekil 2.2 Cinsiyet Tespit Uygulamasının Anlık Görseli

Qt tabanlı masaüstü istemci uygulamasının ilk adımında gerçek zamanlı olarak çalışan bir kamera veya video görüntü kaynağından alınan görüntü yüz algılama sınıflandırıcısına iletilmektedir. Burada yüz algılama sınıflandırması yapılmakta ve algılanmış yüz var ise cinsiyet tespit sınıflandırıcısına iletilmektedir. Yüz algılama gibi gerçek zamanlı görüntü üzerinde çalışan uygulamalarda görüntü kaybı veya donma başlıca sorunlardandır. Bu kapsamda, Qt tabanlı uygulamada yüz algılama sınıflandırıcısı GPU üzerinde sınıflandırma işlemini gerçekleştirecek şekilde ayarlanmıştır. Bu işlem CPU tabanlı tespite göre oldukça hızlı çalışmaktadır.

Geliştirilen sistemde üç farklı sınıflandırıcı eğitilmiştir. Cinsiyet tespit birimine gelen yüz görüntüsü uygulamanın çalıştırıldığı sınıflandırıcıya göre ayrı yollar izlemektedir.

Çalışma anında;


- Fisher yüz algoritması kullanılmışsa, görüntü başarılı resim boyutuna çekilmekte ve sınıflandırıcıdan sonucu elde edilmektedir. Ancak Fisher yüz algoritmasının çalışma zamanı oldukça uzundur. Gerçek zamanlı çalışmalara uygun olmadığından ve geçerli bir başarımlar oranına ulaşamadığından aktif olarak kullanılmamıştır.
- SVM sınıflandırıcısı kullanılmış ise öncelikle öznitelik çıkarım işlemi yapılmaktadır. Öznitelik çıkarım işlemi için SVM ile birlikte kullanılmak üzere LBP veya HOG yöntemleri bulunmaktadır. Bu yöntemlerden hangisi seçilmiş ise, öncelikle yüz görüntüsü üzerinde öznitelik çıkarım yöntemi uygulanmakta ve çıkan sonuç cinsiyet tespit işlemi için SVM'e sunulmaktadır. SVM sınıflandırıcısı, seçilen öznitelik çıkarım yöntemiyle sistem içinde uygun şekilde sistemle çalışabilmektedir.
- CNN sınıflandırıcısı kullanılmış ise doğrudan eğitilmiş modele veri sunulmakta ve sonuç elde edilmektedir. CNN sınıflandırıcısının kullandığı çalışma zamanı oldukça kısadır. Buna ek olarak sınıflandırıcının gerçek zamanlı uygulamada verimini arttırmak için kurulum aşamasında yapılan çalışmalar sonucunda sınıflandırıcı GPU üzerinde çalıştırılmıştır.
- Kullanılmış olan sınıflandırıcının türünden bağımsız olarak belirlediği ve sınıflandırdığı yüz görüntülerine ait cinsiyet etiketi, görseli, uzaklık bilgisi ve zaman bilgileri her yüz görüntüsü için web servise iletilerek sonucu kullanımına sunulmaktadır.

Java EE ile geliştirilmiş web tabanlı sunucu uygulaması, bünyesindeki web servisine iletilmiş bilgileri reklam süre sayacının çalışması durumunda veri tabanına kaydetmektedir. Web tabanlı uygulama sunucusuna erişim adresi, parametre isimleri ve örnek kullanımı Çizelge 2.1'de gösterilmiştir. Buna göre "genderResult" parametresi "1" ise kadın "0" ise erkeği temsil etmektedir. "epoch" parametresi 1 Ocak 1970'den itibaren saymaya başlanmış saat değerini, "distance" parametresi cm cinsinden uzaklık bilgisini ve "path" parametresi resmin kaydedildiği dosya yolunu belirtmektedir.


Eriřim Adresi	http://[ipAdres]:8080/AdvertisingSystem/rest/systemRecord/addRecord
Parametre İsimleri	genderResult, epoch, distance, path
Örnek Kullanım	http://[ipAdres]:8080/AdvertisingSystem/rest/systemRecord/addRecord?genderResult=1&epoch=1528811011&distance=175&path=/home/monster/Desktop/systemImage/1/1528810321

Çizelge 2.1 Web Servis Eriřim Bilgileri

Web uygulaması ilk defa çalıştırıldığında reklam süre sayacının seçilmesi talep edilmektedir. Bu sayaç gelen verilerin dinleneceği aralığı temsil etmektedir. Belirlenen süreye ait sayaç sıfırlandığında baskın olan cinsiyete göre reklam sunulmaktadır. Şekil 2.3'te reklam süre sayacının saniye cinsinden seçimine ait ilgili görsel bulunmaktadır. Uygulama reklam belirleme süresince ekran görüntüsünü her saniye, kadın ve erkek kayıtlarını gösterdiği bölümü ise üçer saniyelik aralıklarla güncellemektedir. Uygulamanın çalışma anına ait örnek bir görsele Şekil 2.4'te yer verilmektedir.



Şekil 2.3 Reklam Süre Sayaç Görseli



Şekil 2.4 Web Uygulamasına Ait Görsel

Web uygulaması, reklam süre sayacının sıfırlanmasıyla süre içinde sayılmış kayıtlar üzerinde daha fazla kayıt içeren cinsiyet etiketini belirlemektedir. Bu karar sonrasında baskın olan cinsiyete sahip kayıtların ortalama uzaklık verisine göre reklam içeriği farklı detay seviyelerinde son kullanıcıya sunulmaktadır.

Sunulan reklam ekranda on saniye kaldıktan sonra sistem sunacağı yeni reklamı belirlemek için işlemlere en baştan başlamaktadır. Bu çalışma şekli, uygulama arayüz üzerinden durdurulmadığı sürece tekrarlanmaktadır.

Sistemde kullanılan cinsiyet sınıflandırıcısı için Fisher Yüz algoritması, SVM ve CNN sınıflandırıcılarından bir tanesi tercih edilmiş olup, gerek daha yüksek çalışma hızı gerekse daha yüksek başarı oranı sunması nedeniyle nihai sistemde CNN cinsiyet tespit sınıflandırıcısı kullanılmasına karar verilmiştir.

2.2. Yüz Algılama

Tez kapsamında geliştirilmiş uzaklık ve cinsiyet tespitine dayalı reklam görüntüleme sisteminde işlenen video görüntülerinden elde edilen yüz veya yüzlerin doğru bir biçimde algılanması, sistemin başarı oranını doğrudan etkilemektedir. Sistemin gerçek zamanlı çalışmasına uygun, verimli ve hızlı çalışabilen bir yöntem üzerinde araştırmalar yapılmıştır. Bu kapsamda dlib kütüphanesinin sahip olduğu nesne algılayıcısından yararlanılmıştır [39]. Bu nesne algılayıcısı; yüz algılama, yaya


tespiti, araç tespiti veya belirlenen objeleri algılama işlemleri için kullanılmaktadır. Ayrıca, belirlenen formattaki verilerle birlikte tekrar eğitilebilmekte ve istenilen amaca göre sınıflandırma yapabilmektedir. Eğitim için kullanılacak yüz görüntüleri bir klasör altında toplanmaktadır. Geliştirilecek yüz algılayıcısı için klasör altındaki her resimde yer alan yüz sınır bilgilerine ihtiyaç duyulmaktadır. Bu kapsamda, dlib kütüphanesinin sunduğu “imglab” aracı ile bu işlemler gerçekleştirilebilmektedir. Ancak WIKI ve IMDB veri setlerindeki yüz resimlerinde yüz sınır bilgileri bulunduğundan doğrudan bu bilgiler kullanılmış ve eğitim için uygun xml dosyası oluşturulmuştur. Şekil 2.5’de örnek olarak verilen xml yapısına ait resim bilgileri görülebilmektedir. Eğitim işlemi için 30.000 görüntü örnek xml yapısına uygun olarak hazırlanmıştır.

```
<?xml version='1.0' encoding='ISO-8859-1'?>
<?xml-stylesheet type='text/xsl' href='image_metadata_stylesheet.xsl'?>
<dataset>
  <name>imglab dataset</name>
  <images>
    <image file='10000217_1981-05-05_2009.jpg'>
      <box top='22' left='97' width='540' height='90'>
        <label>face</label>
      </box>
    </image>
    <image file='10000548_1925-04-04_1964.jpg'>
      <box top='100' left='149' width='491' height='69'>
        <label>face</label>
      </box>
    </image>
  </images>
</dataset>
```

Şekil 2.5 Imglab Örnek Eğitim XML Yapısı

Eğitim seti ve sınır bilgileri tamamlandıktan sonra veri kümesi yüklenmektedir. Varsayılan bilgiler doğrultusunda pencere boyutu 80x80, C parametresi 1 ve epsilon değeri 0.01 olarak belirlenmiştir. Eğitim için HOG öznitelik çıkarım yaklaşımı SVM sınıflandırıcısı ile kullanılmış ve eğitim tamamlanmıştır. Bu işlem sonucunda oluşan sınıflandırıcı kaydedilmiş ve istemci uygulamasının yüz algılama işlemlerinde kullanılmıştır.


Geliştirilmiş yüz algılama sınıflandırıcısının ışık değişimindeki çalışmasına ait örnekler Şekil 2.6'da verilmiştir. Ayrıca, birden fazla kişi olması ve bu kişilerin farklı yüz ifadelerine sahip olması durumlarına ait örnekler Şekil 2.7'de, gözlüklü ve elinde telefon bulunduran kişiye ait örnek ise Şekil 2.8'de gösterilmiştir [40]. Yüz algılama sınıflandırıcısı “WJ-NV200 Face detection sample video clip” adlı video ile test edilmiştir [41].



Şekil 2.6 Yüz Algılama Sınıflandırıcısının Işık Değişimindeki Çalışma Görseli




Şekil 2.7 Yüz Algılama Sınıflandırıcısının Birden Fazla Kişi Olmasıyla Çalışma Görseli



Şekil 2.8 Yüz Algılama Sınıflandırıcısının Gözlük ve Yüz Engelleyen Cisimle Çalışma Görseli

Geliştirilmiş olan sistemde video kaynağından gelen görüntünün çerçeve bazlı işlenmesinde ve ekranda gösterilmesinde OpenCV kütüphanesinin 2.4.9.1 versiyonu kullanılmıştır. OpenCV görüntü işleme ile ilgili çok sayıda bilgi ve fonksiyon içeren açık kaynak kodlu bir kütüphanedir [5]. İşlenen çerçeveler üzerinde yüz algılama çalışmaları için başarımları daha yüksek ve hatalı algılama oranı daha düşük olan dlib kütüphanesinin 19.10 versiyonu kullanılmıştır. OpenCV ve dlib'in yüz algılama sınıflandırıcılarının aynı anda aynı video üzerinde çalıştırılmasında oluşan örnek görüntü Şekil 2.9'da sunulmuştur [42].



Şekil 2.9 OpenCV ve Dlib Karşılaştırma Görseli

Şekil 2.9’da bulunan kırmızı renkli kareler dlib kütüphanesinin, mavi ve yeşil renkli yuvarlaklar ise OpenCV kütüphanesinin tespit ettiği yüz bölgelerine aittir. Buna göre Dlib kütüphanesinin daha başarılı sonuçlar döndürdüğü görülebilmektedir. Dlib kütüphanesi, tüm platformları destekleyen yapısı ve güçlü dokümantasyonu ile yaygın bir biçimde kullanılmaktadır. Dlib makine öğrenimi; derin öğrenme, görüntü işleme, veri madenciliği, XML ve metin ayrıştırma, bilgisayarlı görü algoritmalarını barındıran açık kaynak kodlu bir kütüphanedir. Günümüzde robotik, gölümü sistemler, akıllı cihazlar ve yüksek performanslı çalışmalarda kullanılmaktadır [39].

2.3. Cinsiyet Tespiti

2.3.1. Fisherfaces (Fisher yüz algoritması)

Tez kapsamında Fisher yüz algoritması OpenCV Kütüphanesi ile birlikte cinsiyet tespit sınıflandırması için kullanılmıştır. Algoritmanın OpenCV kütüphanesine uyarlanmış halinde kendisine eğitim ve test aşamasında sunulacak görüntülerin boyutlarının sabit olması beklenmektedir. Örneğin 100x100 boyutunda verilen görüntülerle eğitim yapıldıysa, 100x100 boyutundaki resimlerle test edilmesi beklenmektedir. Bu anlamda, en başarılı sınıflandırıcıyı belirlemek için eğitim setindeki görüntüler 100x100, 140x140, 180x180 ve 220x220 şeklinde tekrar boyutlandırılmıştır. Algoritmanın eğitim aşamasındaki çalışma mantığı gereği tüm görüntüler ham halleri ile rasgele erişimli bellek üzerinde saklanmakta ve buna ek olarak oluşturulmuş olan görüntü vektörü de çalışma zamanında rastgele erişim belleğinde tutulmaktadır. Algoritmanın eğitimi, tez kapsamında kullanılmış eğitim setinin boyutu ile beraber hem süre hem de kaynak bakımından oldukça verimsizdir. Eğitim ve test aşamasında kullanılan resim boyutları tüketilen kaynak miktarı ile birlikte, eğitim ve test aşamasındaki çalışma süresini doğrudan etkilemektedir.

Sonuç olarak Fisher yüz algoritması, gerçek zamanlı yapılması planlanan uygulamalar için hızlı olmayan ve ön işlem gereksinimi yüksek olan bir algoritmadır. Ayrıca eğitim seti ve test setleri arasındaki değişiklikler başarı oranını etkilemektedir. Pentland ve Turk’ün Eigenfaces algoritmasını anlattığı çalışmada da belirtildiği gibi arka plan değişimi, veri kümesindeki farklı ışık içeren ortamlar, görüntüdeki ışık geçişleri ve perspektif görüntüler algoritmayı olumsuz etkilemektedir. Bu sebeple, farklı tarzda görüntüler içeren veri kümesi seçilmesinde

PCA'nın yanlış verileri bulduğu, sınıflandırmada hatalı sonuçlar ürettiği belirtilmiştir [12], [43].

2.3.2. SVM

Tez kapsamında cinsiyet tespit sınıflandırması için SVM makine öğrenme tekniği de denenmiştir. Bu kapsamda SVM'in başarımlarını yükseltmek için birçok çekirdek fonksiyonu ve bu fonksiyonları etkileyecek parametreler bulunmaktadır. Bu çeşitlilik sınıflandırıcısı üzerindeki optimizasyon çalışmalarını zorlaştırmaktadır.

Literatürdeki birçok çalışmada çekirdek fonksiyonu seçiminde RBF tabanlı fonksiyonun seçildiği görülmüştür. Ancak RBF fonksiyonunun her alandaki araştırma veya problemler için uygun olup olmadığı bilinmemektedir. Seçilmiş olan çekirdek fonksiyonunun başarısı veri kümesi ve çalışma yapılan probleme göre değişim gösterebilmektedir [44]. Bu amaçla doğru optimizasyonu yapıp tüm çekirdek fonksiyonlarını inceleyen bir uygulama geliştirilmiştir. Bu uygulamaya ait ayrıntılar Bölüm 4.2'de anlatılmıştır. Geliştirilen optimizasyon uygulamasının sunduğu sonuçlar doğrultusunda cinsiyet tespit sınıflandırmasında RBF çekirdek fonksiyonu ile daha başarılı sonuçlar elde edilmiştir.

Tez kapsamında, SVM cinsiyet tespit sınıflandırıcısı LBP ve HOG öznitelik çıkarma yöntemleriyle ayrı ayrı eğitim ve test süreçlerinden geçirilmiştir. LBP öznitelik çıkarım yöntemi, gri seviyeden bağımsız bir doku ölçüm yöntemidir. LBP operatörü, görüntü üzerindeki her piksele atanmış bir etiket değeri içermekte olup bu değerler sıfır ve birden oluşmaktadır.

Sonuç olarak, SVM makine öğrenme tekniği birçok alanda kullanılabilme, karmaşık karar sınırlarını belirleyebilme ve hem doğrusal hem de doğrusal olmayan şekilde sınırları modelleyebilme özelliklerine sahiptir. Tez kapsamında yapılan optimizasyon çalışmaları sırasında da gözlemlenmiş olan; büyük veri kümeleri için uzun eğitim süreleri, kendi içinde barındırdığı uygun çekirdek fonksiyonunu seçmek ve çekirdek fonksiyonuna bağlı optimizasyonları yapmanın zorluğu bu yöntemin dezavantajları arasında sıralanabilir.

2.3.3. CNN

Tez kapsamında, AlexNet, ZfNet, GoogleNet, MicrosoftResNet gibi derin öğrenme mimari çeşitlerinden GoogleNet kullanılmıştır. 2014 yılında Szegedy, Liu, Jia, Sermanet, Reed, Anguelov, Erhan, Vanhoucke ve Rabinovich tarafından yapılan bir çalışmada yayımlanan GoogleNet, 2014 yılında ImageNet yarışmasını kazanmıştır. İlk CNN mimarilerinden birisi olan GoogleNet, peş peşe gelen konvolüsyon ve havuzlama katmanlarından farklıdır. Yapısı gereği paralel şekilde birbirine bağlı katmanlar kullanılmıştır [45]. GoogleNet, tez kapsamında geliştirilen sınıflandırıcıların hepsinde varsayılan mimarisiyle kullanılmıştır. GoogleNet mimarisinde katmanların hepsinin biriktirilmesi ve yapısında bulunan çok sayıdaki filtre, yüksek bellek gereksinimi ve büyük bir hesaplama maliyeti oluşturmaktadır. Ancak yapısındaki katmanların birbirlerine paralel olarak bağlanmış olması sorunların oluşmasını engellemektedir. Bu mimari başarılı, hızlı ve güçlü yapısıyla cinsiyet tespit sınıflandırıcılarında kullanılmıştır.

CNN ağ çeşidinin eğitim aşamasında kullanılan çözücü (solver) parametreleri bulunmaktadır. Bu parametreler:

- **Training epochs:** Tüm verilerin işlenmesi,
- **Snapshot interval:** Eğitilmiş ağı görüntü, kayıt alma aralığı,
- **Validation interval:** Tanımlanmış olan doğrulama verisi ile derin sinir ağı testi,
- **Batch size:** Girdi olarak beraber alınıp işlenecek resim sayısı,
- **Solver type:** Çözücü, çözümleyici türü,
- **Learning rate:** Öğrenme katsayısı,
- **Policy:** Davranışsal fonksiyon olarak tanımlanabilir.

Derin öğrenmede eğitim Caffe çatısı ile yapılmış olup eğitilmiş modeli temsil eden “caffemodel” uzantılı dosya, eğitimdeki katman ve parametre bilgilerini içeren “prototxt” uzantılı dosya, her bir görüntüden görüntü ortalamasının çıkarılması gerektiğinden ortalama bilgileri içeren “binaryproto” uzantılı dosya ve sınıflandırıcının kullanacağı etiket bilgilerini içeren “txt” uzantılı dosya kullanılmıştır.

2.4. Uzaklık Tespiti

Tez kapsamında, yüz algılama biriminde belirlenen yüz görüntüleri üzerinde cinsiyet tespit işlemi yapıldıktan sonra yüzlerin kameraya olan uzaklıkları tespit edilmektedir. Bu işlem için yüz görüntüsü, cinsiyet etiketi ve kullanılan kameranın odak uzaklık bilgileri gerekmektedir. Yüz görüntüsü üzerinde Şekil 2.10'da gösterilmiş olan insan kulak ön kıkırdakları arasındaki mesafe kullanılmıştır. Bu mesafe bilgisi için literatürdeki araştırmalardan yararlanılmıştır. Araştırmalar, erkeklerin kulak ön kıkırdakları arasındaki ortalama mesafeyi yaklaşık 15.9 cm, kadınlar için yaklaşık 15.0 cm olarak belirlemiştir [46], [47]. Veriler, kulak ön kıkırdakları arasındaki mesafenin cinsiyete göre değiştiğini göstermektedir.



Şekil 2.10 İnsan Yüzündeki Ön Kıkırdak Mesafe Görseli

Kamera kaynağından alınan görüntüler üzerinde kamera üzerindeki merceğin odak piksel değeri için kalibrasyon yapılması gerekmektedir. Bu kalibrasyon için Denklem 2.1'de gösterilmiş olan ve üçgen benzerliğinden gelen formül kullanılmıştır.

$$F = (P \times D) / W \quad (2.1)$$

Odak uzaklığının piksel karşılığını belirleyebilmek için, kişinin cinsiyetine göre değişkenlik gösteren W , cm cinsinden genişlik bilgisini; kamera kaynağından ölçülerek belirlenmiş D , cm cinsinden kişinin duracağı uzaklık bilgisini ve duran kişinin resmi üzerinde tespit edilen yüzüne ait P , piksel bilgisini göstermektedir. Bu bilgiler eşliğinde uygulamada kullanılmak üzere, F odak uzaklığının piksel karşılığı hesaplanabilmektedir.

Örnekle açıklamak gerekirse, bir erkek (15.9 cm) kameraya 100 cm (D) uzaklıkta durmakta iken kameradan alınan görüntüde işlenen çerçeve üzerinden algılanmış yüzün genişliğine ait piksel büyüklüğü (P) 116 piksel ise;

$$\text{Odak piksel değeri (F)} = (116 \text{ piksel} \times 100\text{cm}) / 15.9 \text{ cm}$$

$$F \cong 729.56 \text{ piksel olur.}$$

Böylelikle cinsiyeti tespit edilmiş ve yüz algılaması yapılmış görüntüler üzerinden uzaklık tespit edebilmek için Denklem 2.2'de gösterilmiş olan eşitlik kullanılabilir.

$$D = (W \times F) / P \quad (2.2)$$

Örnekle açıklamak gerekirse, 200 piksel büyüklüğü (P) olan bir yüz görüntüsünün cinsiyet etiket bilgisi kadın (W=15) ise ve odak piksel değeri (F) 729.56 piksel olduğuna göre;

$$D = (15 \text{ cm} \times 729.56 \text{ piksel}) / 200 \text{ cm}$$

$$D = 57.717 \text{ cm uzaklıkta olduğu hesaplanmış olur.}$$


Tez kapsamında kullanılmış olan uzaklık tespit yönteminin oldukça benzeri Matlab geliştirme ortamında uzaklık tespit işlemi için kullanılmaktadır. Matlab'da çalışan fonksiyon öncelikle kullanılan kameraya göre kalibre ederek odak uzaklığının piksek karşılığını bulmakta ve daha sonra uzaklık tespitini gerçekleştirmektedir [48], [49].

3. VERİ KÜMESİ

Veri kümesi, geçmişten günümüze araştırma ve geliştirme konularının artmasıyla birlikte oldukça önemli bir hale gelmiştir. Özellikle örüntü tanıma konularının kullanıldığı yapay zekâ uygulamalarında veri kümesi seçimi, uygunluğu ve büyüklüğü önem arz etmektedir. Bu anlamda günlük hayattaki insan hareketlerinden cinsiyet tespit edebilmeyi amaçlayan sisteme uygun veri kümesi araştırmaları ve seçimleri yapılması gerekmektedir.

Cinsiyet tespit işlemini gerçekleştirecek olan sınıflandırıcı modelinin eğitilmesi gerekmektedir. Bu eğitim aşamasında sınıflandırıcının kullanım alanına uygun veri kümesi veya kümeleri seçilmelidir. Bu anlamda, tez kapsamında geliştirilmiş olan cinsiyet tespit sınıflandırıcılarının her birinde yüksek başarımlar elde etmek için insanların günlük hayattaki hareketlerine uygun yüz görüntülerini içeren veri setleri kullanılmıştır. Geliştirilmiş olan sınıflandırıcıların görmedikleri veriler üzerindeki başarımlarını yükseltmek için birden fazla veri kümesi birleştirilmiştir. Bu mantığa uygun olarak detayları ilerleyen bölümlerde anlatılacak olan LFW, IMDB ve WIKI veri setleri sınıflandırıcıya ait model eğitiminde kullanılırken, FaceScrub veri kümesi modelin testi sırasında kullanılmıştır.

Cinsiyet tespit işlemi, yüz algılama biriminde işlenen çerçevede bulunan yüz görüntülerini içeren kesitleri cinsiyet sınıflandırma birimine girdi olarak vermesiyle gerçekleştirilir. Bu nedenle modellenen sınıflandırıcı eğitim ve test sürecinde cinsiyet tespit ederken girdi olarak yalnız yüz kesitlerini içeren görüntüler üzerinden tahmin işlemini gerçekleştirmelidir. Bu yapıya uygun olarak eğitim ve test veri setlerindeki her bir resme ön işlem yapılması gereği ortaya çıkmaktadır. Cinsiyet tespitinde kullanılmak üzere veri kümelerindeki her bir resimde yüz algılama işlemi yapan ve sonrasında yüz olarak algıladığı bölümleri kırparak eğitim ve test işlemlerine uygun hale getiren bir yaklaşım geliştirilmiştir. Böylece veri kümelerindeki her bir resimde yüz tespit işlemi yapılmış ve uygun olmayan resimler eğitim ve test kümelerinden çıkarılmıştır. Şekil 3.1'de geliştirilen veri kümesi ön işleme yaklaşımına ait görsel bulunmaktadır.



Şekil 3.1 Veri Kümesi Ön İşlem Şeması

Şekil 3.2’de eğitim veri kümesinde bulunan orijinal görüntü ve Şekil 3.3’de eğitim/test veri kümesine eklenen yüz görüntüsünü içeren kısım bulunmaktadır.




Şekil 3.2 Veri Setindeki Görselin Orjinal Hali



Şekil 3.3 Görselin Ön İşlem Sonrasındaki Hali

Eğitim ve test veri kümelerindeki her bir resmin ön işlemden geçirilmesinin yanı sıra geliştirilen Java tabanlı bir diğer uygulama ile resimlere ait etiketler kontrol edilmiştir (Şekil 3.4). Ayrıca cinsiyet tespit sınıflandırıcısının başarımını etkileyebilecek güneş

gözlüklü ve yüzünü kapatacak şekilde kask içeren insan fotoğrafları ile çocuk resimleri veri kümelerinden çıkarılmıştır. Şekil 3.5'te çıkarılan resimlere ait bazı görseller sunulmuştur.



Şekil 3.4 Veri Kümesi Kontrol Uygulaması



Şekil 3.5 Veri Kümesinden Çıkarılan Örnekler

Kullanılan veri setlerindeki verilerin istatistiksel dağılımına ve yapılan ön işlemler sonrasında filtrelenen verilerin dağılımına ait detaylı bilgiler Çizelge 3.1'de gösterilmiştir. Orijinal veri setlerinin bazılarında cinsiyet etiketi mevcut olmayan

resimler bulunmaktadır. WIKI orijinal veri kümesinde 2.643, IMDB’de ise 8.462 resimde cinsiyet etiketi bulunmamaktadır.

Veri Kümesi Adı	Orijinal Veri Kümesi			Filtrelenen Veri Kümesi		
	Kadın	Erkek	Toplam	Kadın	Erkek	Toplam
LFW	2966	10.268	13.234	1424	6309	7733
WIKI	12.622	47.063	62.328	3871	11.669	15.540
IMDB	189.047	263.214	460.723	53.861	71.538	125.399
Face Scrub	51.558	55.307	106.865	20.581	23.949	44.530
Toplam	256.193	375.852	643.150	79.737	113.462	193.202

Çizelge 3.1 Veri Kümesi Çizelgesi

3.1. LFW

LFW, gündelik hayata dair insan resimlerini içeren en güncel veri setlerinden biri olarak gösterilmektedir. LFW veri kümesi, 1.680 kişiye ait toplam 13.234 yüz görüntüsü içermektedir [36]. Veri kümesinde bulunan görüntü örneklerine Şekil 3.6’da yer verilmiştir.



Şekil 3.6 LFW Veri Kümesinden Örnek Görüntüler

LFW veri kümesinde doğrudan cinsiyet bilgilerini içeren etiket bilgisi bulunmamaktadır. Resimlere ait cinsiyet etiketini öğrenmek için ilk isim bilgisini parametre olarak alan ve isime göre cinsiyet bilgisini belli bir olasılık değeri ile döndüren “genderize.io” web servisi kullanılmıştır. Bu web servisi 89 dilde 79 ülkeye

ait 216.286 farklı isim barındırmaktadır. Web servisin çalışmasına ait örnek istek ve sonuçları Çizelge 3.2’de gösterilmiştir.

İstek	Yanıt
https://api.genderize.io/?name=sara	{"name":"sara","gender":"female","probability":0.99,"count":4435}
https://api.genderize.io/?name=peter	{"name":"peter","gender":"male","probability":1,"count":4373}

Çizelge 3.2 Web Servis Örnek Çalışma Çizelgesi

LFW veri kümesindeki resimlere ait cinsiyet etiketi Java programlama dili kullanılarak geliştirilen bir uygulama sağlanmıştır. Cinsiyet etiketine ait bilgiler LFW veri kümesindeki her görüntü için alındıktan sonra geliştirilmiş olan yüz algılama uygulaması ile veri kümesi ön işleme sokulmuş ve resimlerden bazıları elenmiştir. Buna ek olarak cinsiyetlere ait hem etiketlerin doğruluğu hem de görüntünün eğitime/teste uygunluğu Şekil 3.4’te örnek görüntü ile gösterilmiş uygulama üzerinden incelenmiş ve veri setindeki uygun kayıtlar elde edilmiştir.

3.2. IMDB


IMDB veri kümesi yüz görüntülerden oluşan cinsiyet etiketiyle birlikte her kayıt için farklı bilgiler içeren ve herkesin kullanımına açık en büyük veri kümelerindendir. Bu set IMDB web sitesinde listelenmiş en popüler aktör veya aktris listesindeki profil bilgilerinin toplanmasıyla oluşmuştur. Bu bilgilerde her kişiye ait; isim soy isim, doğum tarihi, cinsiyet ve resim bulunmaktadır. Toplamda 20.284 kişiye ait toplam 460.723 yüz görüntüsü bulunmaktadır [50].

IMDB veri setindeki her bir kayıt için aşağıda liste halinde verilmiş bilgiler bulunmaktadır:

- **dob:** Doğum tarihi
- **photo_taken:** Fotoğrafın çekildi yılı
- **full_path:** Fotoğrafa ait dosyanın yolu

- **gender:** Kadın için “0”, erkek için “1” ve bilinmiyorsa “NaN” şeklinde etiket bilgisi
- **name:** Ünlünün adı
- **face_location:** Yüzün konumuna ait bilgi
- **face_score:** Yüz algılamaya ait dedektör puan bilgisi. “Inf” fotoğrafta yüz algılanmadığını ve face_location ögesinin resmin tamamını döndürdüğünü ima eder.
- **second_face_score:** İkinci en yüksek yüz algılamaya ait dedektör puan bilgisi. Bu bilgi birden fazla yüz algılanmasında önem arz eder. Fotoğrafta ikinci yüz algılanmadıysa “NaN” değerini alır.
- **celeb_names:** Tüm ünlü isimlerin listesi
- **celeb_id:** Ünlü isme ait indeks bilgisi

IMDB veri kümesi için Matlab ile açılıp kullanılabilen “mat” uzantılı dosya sunulmaktadır. Bu dosyayı açıp, içinden resimlerin dosya yolunu ve cinsiyet etiket bilgilerini alıp dosyaya yazan Matlab uygulaması geliştirilmiştir. Bu işlemten sonra geliştirilmiş olan yüz algılama uygulaması ile veri setinin tamamı ön işleme sokulmuş ve resimlerden bazıları elenmiştir. Sonrasında veri kümesi üzerindeki kayıtların uygunluğunu ve cinsiyet etiketlerinin kontrolü için Şekil 3.4’te de görülen Java tabanlı uygulama ile kontrol edilmiştir. Veri kümesinde bulunan görüntü örneklerine Şekil 3.7’de gösterilmiştir.



Şekil 3.7 IMDB Veri Kümesinden Örnek Görüntüler

3.3. WIKI

WIKI veri kümesi yüz görüntülerden oluşan cinsiyet etiketinin yanı sıra her kayıt için farklı bilgiler içeren, herkese açık bir veri kümesidir. Bu veri kümesi wikipedia adlı bilgi paylaşım web sitesinde bulunan popüler erkek ve kadınlara ait verilerin bir araya getirilmesiyle oluşturulmuştur. Toplamda 62.328 kişiye ait bilgiler bulunmaktadır [50].

WIKI veri kümesindeki her bir kayıt için aşağıda liste halinde verilmiş bilgiler yer almaktadır:

- **dob:** Doğum tarihi
- **photo_taken:** Fotoğrafın çekildi yılı
- **full_path:** Fotoğrafa ait dosyanın yolu
- **gender:** Kadın için “0”, erkek için “1” ve bilinmiyorsa “NaN” şeklinde etiket bilgisi
- **name:** Ünlünün adı
- **face_location:** Yüzün konumuna ait bilgi
- **face_score:** Yüz algılamaya ait dedektör puan bilgisi. “Inf” fotoğrafta yüz algılanmadığı ve face_location ögesinin resmin tamamını döndürdüğünü ima eder.
- **second_face_score:** İkinci en yüksek yüz algılamaya ait dedektör puan bilgisi. Bu bilgi birden fazla yüz algılanmasında önem arz eder. Fotoğrafta ikinci yüz algılanmadıysa “NaN” değerini alır.

WIKI veri kümesi için, Bölüm 3.2’de anlatılan işlemler aynı şekilde uygulanmıştır. Şekil 3.8’de veri kümesinde bulunan görüntülere ait örnekler sunulmuştur.



Şekil 3.8 WIKI Veri Kümesinden Örnek Görüntüler

3.4. FaceScrub

FaceScrub veri kümesi büyük miktarda yüz verisi üzerinde araştırma yapılacak konuya uygun verilerin bir araya getirilmesindeki zorluğu ortadan kaldırmak için tasarlanmış olup, Vintage grubu tarafından öncelikli olarak yüz algılama konusu için hazırlanmıştır. Bu bağlamda internet üzerinde aranacak kişinin kamuya açık, sorgu yapılabilecek resimleri otomatik olarak taranmaya başlanmıştır. Sonrasında kişiye ait olmayan görüntülerin otomatik olarak atılmasını sağlayan bir yapı ile veri kümesi oluşturulmuştur. En son olarak sonuçlar elle kontrol edilip, temizlenmiştir.

FaceScrub kişi başı yaklaşık 200 görüntüden oluşan 265 ünlü erkek ve 265 ünlü kadın görüntüsünün toplanmasıyla elde edilmiş ve 106.865 resimden meydana gelmiş bir veri kümesidir [51].

Veri kümesinde bulunan erkek ve kadın bilgileri iki ayrı txt uzantılı dosya ile sunulmaktadır. İki dosyada da her bir kayıt için aşağıda liste halinde verilmiş bilgiler yer almaktadır:

- **name:** Ünlünün ad ve soyad bilgisi
- **image_id:** Fotoğrafa atanmış tekil numara
- **face_id:** Fotoğraftaki yüze atanmış tekil numara
- **url:** Ünlü kişiye ait görüntünün olduğu url bilgisi
- **bbox:** URL bilgisinden alınacak yüz görüntüsüne ait sınır noktalarına ait sınır noktası bilgileri

- **sha256:** URL’de bulunan resmin hash değeri ile karşılaştırılarak değişiklik varsa tespit etmek için kullanılan bilgi

FaceScrub veri kümesi için erkekler ve kadınlar için ayrı ayrı sunulan dosyalardan uygun cinsiyet etiketini ve url bilgisinden resmi indiren bir uygulama geliştirilmiştir. Dosyalar üzerindeki bazı kayıtlara ait url bilgileri bulunamamış olup, bazılarının ise hash verileri eşleşmediğinden elenmiştir. Bu işlemin tamamlanmasından sonra geliştirilmiş olan yüz algılama uygulaması ile veri kümesindeki tüm kayıtlar ön işleme tabi tutulmuş ve bir kısmı elenmiştir. Bu işlem sonrasında kalan kayıtların uygunluğunun ve cinsiyet etiket bilgilerinin kontrolü için Şekil 3.4’teki Java tabanlı uygulama kullanılmıştır. Veri kümesinde bulunan görüntü örneklerine Şekil 3.9’da gösterilmiştir.



Şekil 3.9 FaceScrub Veri Kümesinden Örnek Görüntüler

4. DENEYSEL SONUÇLAR

4.1. Geliştirme ve Test Ortam Konfigürasyonları

Tez kapsamında geliştirilmiş olan uzaklık ve cinsiyet tabanlı akıllı reklam görüntüleme sistemi, Linux Ubuntu 16.04 LTS işletim sisteminde Nvidia GeForce GTX 1070 ekran kartı, 64 GB rasgele erişimli bellek (RAM) ve 256 GB katı hal sürücüsü (SSD) donanımlarına sahip bir bilgisayar üzerinde çalışmıştır.

Cinsiyet tespit sınıflandırıcısının eğitiminde kullanılan WIKI ve IMDB veri kümeleri için; “wiki.mat” ve “imdb.mat” dosyalarındaki her kayıt için sunulmuş olan bilgilerden resimlere ait dosya yolunu ve cinsiyet etiket bilgisini almak için Matlab ortamında bir uygulama geliştirilmiştir.

WIKI veri kümesine ait bilgileri içeren “wiki.mat” dosyasının içeriğine ait bilgileri Bölüm 3.3’te sunulmuştur. Şekil 4.1’de wiki.mat’a ait örnek bir görsel bulunmaktadır.

Field ▲	Value
dob	1x62328 double
photo_taken	1x62328 double
full_path	1x62328 cell
gender	1x62328 double
name	1x62328 cell
face_location	1x62328 cell
face_score	1x62328 double
second_face_score	1x62328 double

Şekil 4.1 wiki.mat’a Ait Görsel

IMDB veri kümesine ait bilgiler içeren “imdb.mat” dosyasının içeriğine ait bilgiler Bölüm 3.2’de sunulmuştur. Şekil 4.2’de imdb.mat’a ait örnek bir görsel sunulmuştur.

Field ▲	Value
dob	1x460723 double
photo_taken	1x460723 double
full_path	1x460723 cell
gender	1x460723 double
name	1x460723 cell
face_location	1x460723 cell
face_score	1x460723 double
second_face_score	1x460723 double
celeb_names	1x20284 cell
celeb_id	1x460723 double

Şekil 4.2 imdb.mat'a Ait Görsel

Geliştirilen masaüstü uygulamasında Qt çatısı kullanılmıştır. Qt çatısının kullanıcılara sunduğu en büyük avantaj, C++'ın yüksek performansını Qt'nin desteklediği görsellikle birleştirilerek kullanımına olanak sağlamasıdır. Ayrıca Qt, C++ kullansa da Python, Java, Ruby, C# gibi farklı dillerle de bağlantılı olarak kullanılabilir [52]. Tez kapsamında geliştirilmiş olan yüz algılama ve cinsiyet tespit sınıflandırıcıları Qt Creator 5.7 geliştirme ortamında Qt ile birleştirilerek bütünleştirilmiş bir uygulama haline getirilmiştir [53]. Bu uygulama işlediği görüntüler üzerinden tespit ettiği yüzlerin cinsiyet etiketini, yüz görüntüsünü ve uzaklık bilgisini web uygulamasının web servisine yönlendirir. Web servise gelen veriler 3.4 versiyonlu MongoDB veri tabanına kaydedilir. Qt çatısı altında, veri setlerinde bulunan görüntüler üzerinde çalışan yüz algılayıcı kontrol uygulaması geliştirilmiştir. Bu uygulama sayesinde eğitim ve test veri kümelerinin kontrolü yapılmıştır. Bu kontrol sonrasında yüz algılama yapılamamış veriler kümeden çıkarılmıştır. Veri kümelerinden çıkarılmış olan görüntülere ait örnek bir resim Şekil 4.3'te sunulmuştur.



Şekil 4.3 Veri Kümesinden Çıkarılan Görüntü Örneği

Böylelikle Şekil 3.5'te örnekleri verilen ve yüz algılama kontrol uygulamasından başarıyla geçmiş bazı resimler, geliştirilmiş olan elle kontrol uygulaması aracılığıyla veri kümesinden çıkarılmıştır.

Tez kapsamında veri tabanından verilerin çekilerek son kullanıcıya gösterilecek reklam işleminin belirlenmesi ve gösterilmesi için web tabanlı bir Java uygulaması geliştirilmiştir. Geliştirilen web uygulaması Apache Tomcat 8.5 versiyonlu uygulama sunucusu üzerinde ve Eclipse Neon geliştirme ortamında çalışmaktadır. Ayrıca LFW, FaceScrub veri setleri üzerinde yapılan işlemler için Java 8 ile geliştirme yapılmıştır. Ek olarak geliştirilmiş olan yüz algılama uygulamasından geçen kayıtlar Şekil 3.4'te gösterilmiş olan Java programlama dili ile yazılmış veri kümesi kontrol uygulamasıyla kontrol edilmiştir.

Derin öğrenme için çok farklı ve çeşitli çatılar bulunmaktadır [54]. Bu çatılardan bazıları;

- TensorFlow
- Caffe
- Caffe2
- Torch

- MXNet
- Chainer
- Keras, olarak sıralanabilir.

Tez kapsamında derin öğrenme ağ çeşitlerinden CNN kullanılarak geliştirilmiş olan sınıflandırıcı için Caffe derin öğrenme çatısı tercih edilmiştir. Caffe, BVLC ve kullanıcı topluluğu tarafından açık kaynak kodlu olarak geliştirilmekte, günümüz akademik araştırma projelerinde ve geniş ölçekli uygulamalarda sıklıkla kullanılmaktadır [55]. Hızlı ve modüler şekilde tasarlanmış bir yapısı olması, yeni fikirleri denemeye ve genişletilebilir kod yapısı ile aktif geliştirmeye olanak sağlamaktadır. Caffe'nin, C++, Matlab, Python gibi farklı dillerde yazılmış versiyonları bulunmaktadır [54]. Ek olarak Caffe 2 2017 Nisan ayında Facebook ile yapılan ortak çalışma ile çıkarılmıştır.


Caffe, CPU ile kullanılabilmesinin yanı sıra NVIDIA'nın geliştirdiği CUDA çekirdeklerini kullanarak GPU üzerinde paralel hesaplama desteği de sağlamaktadır. Böylelikle CPU üzerinde seri bir şekilde hesaplaması yapılan işlemler GPU kullanımı sayesinde paralel bir şekilde yapılabilmekte ve hesaplama performansında büyük ölçüde artışa olanak sağlamaktadır. Caffe'nin GPU desteği görüntü işlemenin yanında, ses tanıma, robotik, astronomi, sinir bilimi, sismik analiz, ışın izleme gibi birçok alanda kullanılmaktadır [56].

Caffe çatısı, bünyesinde önceden eğitilmiş modeller, ağ yapıları ve örnek çalışmaları içermektedir. Böylelikle geliştirme yaparken önceden geliştirilmiş çalışmaları da kullanabilmeye olanak sağlamaktadır. Kullanım olarak herhangi bir program yazmadan komut satırı üzerinden belirlenmiş olan anahtar kelimeler aracılığı ile kullanılmaktadır.

Caffe'nin Linux kurulumu için öncelikle makinedeki GPU ile uyumlu ve kararlı bir şekilde çalışan versiyonunun temin edilmiş olması gerekmektedir. Bu kapsamda, NVIDIA'nın 384.111 versiyonlu sürücü kütüphanelerinin uyumlu olduğu görülmüş ve yüklenmiştir. NVIDIA'nın sitesinden CUDA 8.0 dosyası indirilmiş ve kurulmuştur. Kurulum sonrasında işletim sistemi tarafından kullanımı için sistem değişkenlerine eklenmiştir. Daha sonra NVIDIA'nın derin öğrenme için özel olarak geliştirilmiş cuDNN isimli kütüphanesi indirilmiştir. cuDNN GPU işlemlerinde, konvolüsyon,


havuzlama gibi katmanlarda hızlandırmak için kullanılmaktadır. Hızlandırmayı sağlaması için gerekli dosyalar CUDA'nın bulunduğu klasöre konmuştur. Bu işlemten sonra Caffe'nin kaynak kodu indirilip, bağımlılık içeren uygulamaların kurulumu tamamlanmıştır [57]. Sonrasında, "caffe" klasöründeki "Makefile.config" dosyası üzerinde GPU ve cuDNN kullanımı ve CUDA dosya yolu ile ilgili konfigürasyon ayarları yapıldıktan sonra derlenip, test edilmiş ve sistem üzerinde kullanımına başlanılmıştır [55] .

Digits, NVIDIA tarafından geliştirilmiş olan ve Caffe ile entegrasyonunun yapılmasıyla web arayüzü sağlayan uygulamadır. Çalışmadan önce Caffe'nin kurulu olduğu dosya yolu bilgisini ister ve varsayılan portu 5000'dir. Digits hızlı bir şekilde deri öğrenme tasarımı yapmayı, eğitilen modelin gerçek zamanlı bilgilerini izlemeyi, çoklu GPU kullanımında paralel olarak birçok derin öğrenme sınıflandırıcısının eğitimini gerçekleştirme olanağı sunar [58], [59]. Ayrıca, Digits üzerinden veri kümesi ekleme işlemi yapılabilir. Tez kapsamında Digits aracılığıyla veri kümesi ekleme işlemi sonrasında ait görsel Şekil 4.4'te gösterilmiştir. Buna göre şekilde görülen eksenlerden yatay eksen cinsiyet etiketlerine ait verileri, dikey eksen ise toplam resim sayısını göstermektedir.



Şekil 4.4 Digits Veri Setine Ait Görsel

Digits üzerinde geliştirilen sınıflandırıcı modeline ait konfigürasyon ve optimizasyonların yapılması sonrasında eğitim aşamasındaki durum gözlemlenebilmektedir. Tez kapsamında eğitilen modelin canlı durumunun gözlemlendiği ekran görüntüsü Şekil 4.5'dedir. Buna göre, şekilde yer alan eksenlerden sol dikey kısım kayıpları, sağ dikey kısım başarı yüzdesini, yatay düzlem ise devir sayısını göstermektedir. Şekildeki görsel eğitim aşamasındaki modelin canlı olarak izlenmesine ve analiz yapılmasına olanak sağlamaktadır.



Şekil 4.5 Deri Öğrenme Modeline Ait Canlı Durum Görseli

Ek olarak Digits üzerinde eğitilmiş modelin eğitim sırasındaki grafiği incelenebilmekte, istatistiksel veriler gözlemlenebilmekte, model ve modele ait dosyalar indirilebilmektedir. Ayrıca eğitilmiş olan modellerin listesi görüntülenebilmektedir. Tez kapsamında eğitilmiş ve optimizasyon işlemleri yapılmış modellerin Digits üzerindeki görünüşüne dair görsel Şekil 4.6'dadır.

name	extension	framework	status	elapsed	submitted	accuracy (val) last
▼ genderModel						
genderModel_sgd_snapshot_5_policy_fixed		caffe	Done	8h	Oct 29, 17	0.9
genderModel_sgd_snapshot_5_policy_polynomialDecay_power_2		caffe	Done	8h	Oct 26, 17	0.94
genderModel_sgd_snapshot_5_batchSize_8		caffe	Done	8h	Sep 17, 17	0.93
genderModel_sgd_snapshot_5_batchSize_16		caffe	Done	8h	Sep 17, 17	0.94
genderModel_sgd_snapshot_5_batchSize_32		caffe	Done	8h	Sep 16, 17	0.94
genderModel		caffe	Done	8h	Sep 11, 17	0.94
▼ genderModel2						
genderModel_nag_snapshot_5_batchSize_16		caffe	Done	8h	Oct 29, 17	0.92
genderModel_nag_snapshot_5_policy_polynomialDecay_power_2		caffe	Done	8h	Oct 26, 17	0.94
genderModel_nag_snapshot_5_batchSize_8		caffe	Done	8h	Sep 18, 17	0.99
genderModel_nag_snapshot_5_batchSize_16		caffe	Done	8h	Sep 18, 17	0.94
genderModel_nag_snapshot_5_batchSize_32		caffe	Done	8h	Sep 17, 17	0.94
genderModel_nag_snapshot_5		caffe	Done	8h	Sep 12, 17	0.94
▼ genderModel3						
genderModel_adagrad_snapshot_5_policy_fixed		caffe	Done	8h	Oct 30, 17	0.94
genderModel_adagrad_snapshot_5_policy_polynomialDecay_power_2		caffe	Done	8h	Oct 27, 17	0.93
genderModel_adagrad_snapshot_5_batchSize_8		caffe	Done	8h	Sep 20, 17	0.92
genderModel_adagrad_snapshot_5_batchSize_16		caffe	Done	8h	Sep 19, 17	0.93
genderModel_adagrad_snapshot_5_batchSize_32		caffe	Done	8h	Sep 19, 17	0.93
genderModel_adagrad_snapshot_5		caffe	Done	8h	Sep 13, 17	0.93

Şekil 4.6 Eğitilmiş CNN Modellerine Ait Görsel

Her modellenmiş sınıflandırıcının kendisine ait dosyaları bulunmaktadır. Bunlar;

- Ağ Model Dosyası: Ağ yapısını gösteren dosya
- Çözücü Dosyası: Eğitim parametrelerinin belirtildiği dosya
- Ağırlık Dosyası: Eğitim sonrasında oluşturulan modellenmiş ağa ait bilgilerin tutulduğu “.caffemodel” uzantılı dosya, olarak açıklanabilir.

Sonuç olarak, Caffe GPU'ya uygun şekilde derlenmiş olup eğitilmiş modele ait oluşturulmuş dosyalar Qt çatısı altında geliştirilmiş olan sisteme entegre edilerek kullanımı sağlanmıştır [59].

Tez çalışması boyunca kullanılan sisteme görüntü sağlayan kamera 15 FPS değeriyle çalıştırılarak test edilmiştir.

4.2. Değerlendirme Sonuçları ve Tartışma

Tez kapsamında geliştirilmiş olan sistemle uzaklık ve cinsiyet bazlı reklam üreten akıllı bir uygulama geliştirilmiştir. Farklı cinsiyet tespit yöntemleriyle geliştirilen sınıflandırıcılar kullanılmıştır. Bu sınıflandırıcılar için kendi içlerinde optimizasyon çalışması yapılmıştır.

Fisher yüz yönteminin eğitim, test ve gerçek zamanlı çalışma aşamalarındaki girdi boyutlarının aynı olması gerekmektedir. Test ve gerçek zamanlı çalışma anında eğitim aşamasındaki boyut bilinerek görüntü tekrar boyutlandırılıp daha sonrasında sınıflandırıcıya eklenmesi gerekmektedir. Bu amaçla farklı boyutlardaki görüntülerle eğitim ve test işlemi gerçekleştirilmiştir. Fisher yüz algoritma yöntemi dört farklı boyut ile eğitilmiş ve FaceScrub veri kümesi üzerinde test edilmiştir. Farklı boyutlarla yeniden kullanılan görüntüler üzerindeki başarı oranlarına ait sonuçlar Çizelge 4.1’de sunulmuştur. Buna göre Fisher yüz algoritma yöntemi ile elde edilen en yüksek başarı oranının 180x180’lik resim boyutunda elde edildiği gözlemlenmiştir.

Resim Boyutu	Başarı Yüzdesi (%)
100x100	53.6
140x140	56.1
180x180	61.3
220x220	59.7

Çizelge 4.1 Fisherfaces Farklı Boyutta Başarı Çizelgesi

SVM makine öğrenme yönteminde optimizasyon işlemleri için uygun çekirdeği seçmek ve doğru parametreleri bulmak büyük önem arz etmektedir. Literatürde doğrudan çözümler olmadığından tez kapsamında doğru optimizasyon parametrelerini bulmak için tüm çekirdek fonksiyonlarını ve fonksiyonlardaki değişken parametreleri eğitim ve test aşamalarından geçiren bir uygulama geliştirilmiştir. Şekil 4.8’de örnek parametre değerleri görülebilmektedir. Burada seçilen çekirdek fonksiyonuna göre parametre değerleri ve öznitelik çıkarma yöntemi belirlenir. LBP ve HOG öznitelik çıkarma yöntemlerinin her ikisi için de uygulama çalıştırılmıştır. Parametre değerlerinin minimum, maksimum ve artış değerleri belirlenmiştir. Epsilon ve maksimum iterasyon sayısı sabit olarak atanmıştır. Eğitim için, Şekil 4.7’de görülen durum örnekle açıklanırsa, kernel değeri 2 iken RBF çekirdeği kullanılmaktadır. RBF fonksiyonunda Gamma ve C parametreleri etkin rol oynamaktadır. Bu parametrelerin ikisi de belirlenen aralıkta artış değerlerine bağlı olarak eğitimde kullanılmaktadır. Bu parametrelere bağlı olarak Gamma parametresi 0.01 değeriyle, C parametresi 0.01 değeriyle ilk eğitimi

gerçekleştirdikten sonra Gamma parametresi 0.01'e sabitlenip C parametresine 10 eklenir. Böylelikle C'nin değeri 10.01 olur ve bu şekilde başka bir SVM sınıflandırıcısı oluşturulur. C parametresi belirlenen maksimum değere ulaştıktan sonra Gamma parametresi 0.21 değerini alırken, C parametresi tekrar 0.01 değerinden eğitime başlar.

```
kernel|2|lin=0,poly=1,rbf=2,sigmoid=3
gamma_low|0.01|
gamma_high|2|
gamma_step_size|0.2|
c_low|0.01|
c_high|100|
c_step_size|10|
degree_low||
degree_high|
degree_step_size||
coef0_low||
coef0_high||
coef0_step_size||
max_iter|10000|
epsilon|1e-06|
```

Şekil 4.7 SVM Optimizasyon Uygulamasının Parametre Görseli

Çizelge 4.2'de SVM ile optimizasyon sonucu elde edilmiş en başarılı sonuçlar sunulmuştur. Buna göre HOG öznitelik çıkarım yöntemi ile oluşturulan SVM sınıflandırıcısının daha yüksek başarı oranına eriştiği gözlemlenmiştir.

Sınıflandırıcı	Çekirdek Fonksiyonu	Öznitelik Yöntemi	Başarı Yüzdesi (%)
SVM	RBF	HOG	80.58
SVM	RBF	LBP	75.32

Çizelge 4.2 SVM Optimizasyon Sonrası En Başarılı Sınıflandırıcılar

Tez kapsamında kullanılan derin öğrenme ağ çeşitlerinden CNN'in eğitim ve test süreçleri GoogleNet mimarisi ile gerçekleştirilmiştir. Eğitilen CNN sınıflandırıcılarından en yüksek doğruluk yüzdesine sahip yirmi sınıflandırıcıya ait bilgi ve parametreler Çizelge 4.3'te sunulmuştur.

	Çözücü Türü	Toplu İş Sayısı	İlke	Doğruluk Yüzdesi
1	SGD	8	Adım	94.76
2	NAG	32	Adım	94.58
3	SGD	32	Adım	94.52
4	NAG	16	Adım	94.47
5	SGD	16	Adım	94.27
6	RMSprop	16	Sabit	94.21
7	SGD	32	Adım	94.12
8	RMSprop	32	Çok Terimli Azalım	94.05
9	AdaGrad	32	Sabit	93.90
10	AdaGrad	32	Adım	93.82
11	AdaGrad	16	Adım	93.70
12	SGD	16	Çok Terimli Azalım	93.55
13	NAG	16	Çok Terimli Azalım	93.47
14	NAG	16	Sabit	93.46
15	AdaGrad	32	Adım	93.11
16	AdaDelta	16	Sabit	93.06
17	AdaDelta	8	Sabit	93.05
18	AdaDelta	16	Adım	92.91
19	SGD	16	Sabit	90.91
20	NAG	8	Adım	89.04

Çizelge 4.3 Eğitilmiş En Yüksek Başarım Yüzdesine Sahip Sınıflandırıcılar

CNN, optimizasyon işlemleri için belirlenen parametrelerle eğitim işlemlerini GPU üzerinde gerçekleştirilmesine olanak sağlandığından diğer iki makine öğrenme metoduna göre oldukça hızlı ve detaylı bilgilendirici görselleri sayesinde başarılı bir şekilde tamamlanmıştır.

Eğitim ve kendi içinde optimizasyon çalışmaları yapılmış cinsiyet tespit yöntemlerini birbirleriyle karşılaştırabilmek için her sınıflandırıcının belirlenmiş veri kümesi

üzerinde sonuçları alınmıştır. Bu işlem için FaceScrub veri kümesi başarı oranını ölçmek amacıyla kullanılmıştır. Veri kümesinde erkek ve kadınlara ait görseller iki ayrı dosya halinde bulunmaktadır. Resimler bu dosyalarda belirlenmiş adreslerden indirilmiştir. Her resim cinsiyet tahmin işleminde önce yüz algılama katmanına girdi olarak verilmiş ve yüz algılaması yapılabilenler sınıflandırıcı için belirlenmiş ön koşullarla birlikte nihai tahminler elde edilmiştir. Çizelge 4.4'te yapılan test sonucuna ait tablo bulunmaktadır.

Sınıflandırıcı Türü	Doğruluk Yüzdesi (%)
Fisherfaces	61.3
SVM_LBP	75.32
SVM_HOG	80.58
GenderNet	84.79
CNN	94.76

Çizelge 4.4 Test Edilmiş Cinsiyet Tespit Sınıflandırıcıları Başarım Oran Çizelgesi

Deneylerin yapıldığı Fisher yüz sınıflandırıcısından düşük bir başarı oranı elde edilmiştir. FaceScrub veri kümesi sonuçlarına göre SVM sınıflandırıcısı ile beraber kullanılmış olan HOG öznitelik çıkarımının LBP öznitelik çıkarımına göre daha yüksek doğruluk oranına sahip olduğu gözlemlenmektedir. Ayrıca, derin öğrenme temelli sınıflandırıcıların klasik makine öğrenme seçenekleriyle eğitilmiş sınıflandırıcılardan daha üstün başarıma ulaşıldığı görülebilmektedir. Bu bağlamda geliştirilmiş olan CNN tabanlı cinsiyet tespit sınıflandırıcısının literatürde yer alan GenderNet sınıflandırıcısına göre daha yüksek doğruluk oranına ulaştığı görülebilmektedir.

Derin öğrenme temelli sınıflandırıcılarla klasik makine öğrenme temelli sınıflandırıcı seçeneklerini kullanarak geliştirilmiş olan metotların karşılaştırılmasında başarı oranı en önemli kıstas olarak görülmektedir. Klasik makine öğrenme seçenekleri kullanarak geliştirilen bir modelin tanıma işlemindeki başarı oranını arttırmak için oldukça zor bir işlem olan öznitelik vektör çıkarımı yapılması gerekmektedir. Bu sebeple klasik makine öğrenme teknikleri veri üzerinde ön işlem yaptıktan sonra

işlemlere devam etmektedir. Oysa derin öğrenmede bu süreç olmamakta ve öğrenme işlemi ham veri ile yapılmaktadır. Bir diğer deyişle öğrenim işlemi için gerekli bilgiler derin öğrenmenin yapısındaki farklı katmanlar sayesinde ham veriden elde edilmektedir.

SVM tabanlı geliştirilmiş olan cinsiyet tespit sınıflandırıcısı eğitim sonrasında belirlenmiş parametrelere göre yaklaşık 3 ila 3.5 GB boyutlu dosyalar oluşturmaktadır. Gerçek zamanlı bir uygulamanın çalışma sürecinde bu büyüklükte bir verinin yüklenmesi oldukça zaman almakta ve tahmin işlemi gerçek zamanlı uygulamalara uygun şekilde çalışmamaktadır. Ek olarak, rastgele bellek hafızası üzerinde kapladığı alan fazla kaynak tüketimine sebep olmaktadır.

CNN tabanlı geliştirilmiş olan cinsiyet tespit sınıflandırıcısı eğitim sonrasında belirlenmiş parametrelere göre yaklaşık 250 ila 300 MB'lık dosyalar oluşturmaktadır. Bu dosyaların sınıflandırıcının çalışma zamanında uygulamaya yüklenmesi oldukça kısa zaman almakta ve tahmin işlemlerini GPU üzerinde yapacak şekilde geliştirildiği için GPU'ya ait RAM üzerinde çalışmaktadır. Böylelikle sistemin koştuğu CPU üzerinde herhangi ekstra bir yüke sebep olmamaktadır. GPU üzerinde çalışan bu sınıflandırıcı 5 ila 10 milisaniye gibi oldukça kısa bir sürede cinsiyet tahmin işlemini başarılı bir şekilde gerçekleştirebilmekte ve gerçek zamanlı çalışan uygulamanın zamanın gerisinde kalmadan uygun şekilde çalışmasını sağlamaktadır.

Uzaklık tespitinin doğrulanmasına yönelik olarak küçük bir veri grubu üzerinde iki farklı test yapılmıştır. Buna göre 4 kadın ve 3 erkek denek farklı mesafelerde yer alarak sistemin ölçtüğü uzaklıklar ve RMSE [60] değerleri hesaplanmıştır. Elde edilen sonuçlar Çizelge 4.5 ve Çizelge 4.6'da sunulmuştur. RMSE değeri Denklem 4.1'deki gibi hesaplanmakta olup X_{Act} değeri gerçek mesafeyi X_{Obs} değeri ise ölçülen mesafeyi göstermektedir. RMSE değerleri denekler 100 cm uzaklıkta iken 12.51 cm, 150 cm uzaklıkta iken 14.28 cm olarak hesaplanmıştır.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(X_{Act_i} - X_{Obs_i})^2}{N}} \quad (4.1)$$

Denek No & Cinsiyet	Gerçek Mesafe (cm)	Ölçülen Mesafe (cm)	$(X_{Act_i} - X_{Obs_i})^2$
Denek1 (Erkek)	100	100	$(100 - 100)^2$
Denek2 (Erkek)	100	100	$(100 - 100)^2$
Denek3 (Erkek)	100	110	$(100 - 110)^2$
Denek4 (Kadın)	100	100	$(100 - 100)^2$
Denek5 (Kadın)	100	120	$(100 - 120)^2$
Denek6 (Kadın)	100	114	$(100 - 114)^2$
Denek7 (Kadın)	100	120	$(100 - 120)^2$
RMSE = 12.51 cm			

Çizelge 4.5 Denekler 100 cm Uzaklıktayken

Denek No & Cinsiyet	Gerçek Mesafe (cm)	Ölçülen Mesafe (cm)	$(X_{Act_i} - X_{Obs_i})^2$
Denek1 (Erkek)	150	173	$(150 - 173)^2$
Denek2 (Erkek)	150	144	$(150 - 144)^2$
Denek3 (Erkek)	150	158	$(150 - 158)^2$
Denek4 (Kadın)	150	161	$(150 - 161)^2$
Denek5 (Kadın)	150	164	$(150 - 164)^2$
Denek6 (Kadın)	150	161	$(150 - 161)^2$
Denek7 (Kadın)	150	169	$(150 - 169)^2$
RMSE = 14.28			


Çizelge 4.6 Denekler 150 cm Uzaklıktayken

Sistemdeki web uygulamasına gelen veriler doğrultusunda art arda çalışan dört reklam döngüsü için test yapılmış ve Çizelge 4.7’te ayrıntılarına yer verilmiştir.

Sıra No	Başlangıç Zamanı	Bitiş Zamanı	Erkek Kayıt Sayısı	Kadın Kayıt Sayısı	Baskın Cinsiyete Ait Ortalama Uzaklık	Sonuç
1	14:03:08	14:03:28	132	258	210	Kadınlara özgü reklam
2	14:03:40	14:04:00	104	315	97	Kadınlara özgü reklam
3	14:04:11	14:04:22	420	446	67	Kadınlara özgü reklam
4	14:04:32	14:04:42	342	324	145	Erkeklerle özgü reklam


Çizelge 4.7 Reklam Döngüsü Test Sonuçları

Bu test sırasındaki web uygulamasının anlık görsellerinden bazıları Şekil 4.8, 4.9, 4.10, 4.11 ve 4.12’de sunulmuştur. Buna göre, 20 saniyelik bir reklam sayacı içinde Şekil 4.8’de sistemin yeni başladığı ve ilk saniyede herhangi bir kayıt olmadığı görülebilmektedir.




Şekil 4.8 Web Uygulaması Anlık Görsel-1

Sistemin reklam belirleme çalışmasının 4. saniyesindeki anlık görüntü Şekil 4.9’da sunulmuştur. Buna göre, 4. saniyede erkeklerin kayıt sayısı 106 iken kadınlara ait herhangi bir kayıt bulunmadığı görülebilmektedir.




Şekil 4.9 Web Uygulaması Anlık Görsel-2

Şekil 4.10'da görülebileceği gibi 11. saniyede erkeklerin kayıt sayısı 350 iken, kadınların kayıt sayısı 72'dir.



Şekil 4.10 Web Uygulaması Anlık Görsel-3

Şekil 4.11'de 18. saniyede erkeklere ait kayıt sayısı 420 iken, kadınlara ait sayı 345'tir.



Şekil 4.11 Web Uygulaması Anlık Görsel-4

Sistem, 20. saniyenin sonunda saydığı erkek ve kadın sayılarından baskın olan cinsiyeti belirlemektedir. Sonrasında baskın olan cinsiyete ait kayıtların uzaklıklarının aritmetik ortalamasını alarak reklamda gösterilecek içeriğin detayına karar vermektedir. Şekil 4.12’de görülebileceği gibi son 2 saniye içinde daha fazla kadın etiketli kayıt oluşmuş ve reklam kadınlara göre sunulmuştur.

Şekil 4.12’deki görsel, ekranda 10 saniye durduktan sonra sistem Şekil 4.8’deki gibi reklam belirleme çalışmasına baştan başlamaktadır. Yeni döngüye geçilmesiyle beraber “sequenceNo” bir arttırılmaktadır. Ayrıca, önceki döngüden kalan ortalama uzaklık bilgisi ile birlikte kadın ve erkek kayıt sayıları da sıfırlamaktadır.

Results

Male count:
420

Female count:
446

Distance:
67

Advertisement



- Akşam yemeklerinize şıklık katacak,
- Sivri burunlu ve yüksek topuklu (10 cm),
- %100 gerçek deri,
- Fiyat: 399.99 TL

Şekil 4.12 Reklam Öneri Görseli-1

Bir diğer örnek çalışmada ise, Şekil 4.13'te görülebileceği gibi erkek etiketli kayıtlar daha fazla olmasından dolayı reklam erkeklere özgüdür. Burada gösterilen reklamın içeriği ortalama uzaklık bilgisine göre değişim göstermektedir.



Şekil 4.13 Reklam Öneri Görseli-2

Şekil 4.14'te sunulan reklam önerisinde ise, baskın olan erkek cinsiyetine ait ortalama uzaklık bilgisine göre sunulan reklam önerisindeki detayların değişimi görülmektedir. Ortalama uzaklık arttığı için reklamın detay seviyesi azaltılmıştır.

Results

Male count:

78

Female count:

54

Distance:

335

Advertisement



- Doğal, otantik ve modern koku,
- Muhteşem okyanus şişesinde,

Şekil 4.14 Reklam Öneri Görseli-3

5. SONUÇLAR

Günümüzdeki dijitalleşen dünyanın getirdiği yoğun rekabet ortamında reklam konusunda; içeriklerin farklılaşabilmesi, tüketici beklentilerinin dinamik olarak sağlanabilmesi ve kitlesel reklamcılıktan bireyselliğe geçebilmek büyük önem arz etmektedir. Bu aşamadaki yenilikçi reklam anlayışını destekleyebilmek için yapılan tez çalışmasıyla gereksinimler ve gerekli teknolojiler ayrı ayrı ele alınmıştır.

Tez çalışması kapsamında, dijital ekran üzerinde çalışan akıllı bir reklam görüntüleme sistemi geliştirilmiştir. Sistem işlediği görüntüler üzerinde yüz algılama, cinsiyet tespiti ve uzaklık tespiti yaparak kullanıcıya özgü farklı detay seviyelerinde reklam sunabilmektedir. Bunu yapmak için belirlenmiş zaman dilimleri içerisinde çeşitli istatistiksel hesaplamalar yaparak ekrana bakan insan grubunun cinsiyet ve uzaklığını dikkate almaktadır.

Sistem iki ana uygulamadan oluşmaktadır. Qt tabanlı istemci uygulaması kendi içinde alt modüller içermektedir. Bunlar; yüz algılama, cinsiyet tespiti ve uzaklık tespiti olarak belirtilebilir. Yüz algılama sınıflandırıcısı olarak dlib'in nesne algılayıcısı üzerine yüz algılama sınıflandırıcısı eğitilmiş ve sistem içinde GPU üzerinden sınıflandırma yapacak şekilde kullanılmıştır. Cinsiyet tespit sınıflandırıcısı için Fisher yüz, SVM ve CNN sınıflandırıcıları eğitilmiştir. Fisher yüz algoritması kullanılarak geliştirilen sınıflandırıcı, eğitim süresi, kullandığı kaynak miktarı ve başarı yüzdesi düşük olduğundan gerçek zamanlı uygulamada kullanılmamıştır. Geliştirilmiş olan SVM sınıflandırıcısında optimizasyon işleminin yapılması farklı çekirdek ve parametreler içerdiğinden dolayı oldukça zordur. Bu optimizasyon çalışması için geliştirilmiş olan uygulamayla birlikte belirlenen parametre aralıkları taranmış ve optimal parametreler bulunmuştur. SVM sınıflandırıcısı, LBP ve HOG öznitelik çıkarım yöntemleri ile ayrı ayrı kullanılmış ve yapılan testlerde SVM'in HOG öznitelik çıkarım yöntemi ile daha başarılı sonuçlar ürettiği saptanmıştır. CNN sınıflandırıcısı Caffe derin öğrenme çatısı altında Digits uygulamasıyla birlikte eğitilmiş ve test edilmiştir. Caffe'nin GPU üzerinden eğitim sağlaması, süre ve optimizasyon bakımından büyük kolaylık sağlamıştır. Ayrıca sistemde yapılacak cinsiyet tespit sınıflandırmaları çalışma zamanında GPU üzerinden gerçekleştirilmiştir.

Eđitilmiş sınıflandırıcıların birbirleriyle karşılaştırılması sonucunda başarıml oranı yüksek, tahmin süresi kısa ve tükettiđi kaynak miktarı az olan CNN derin öğrenme sınıflandırıcısı en başarılı sınıflandırıcı olarak belirlenmiş ve gerçek zamanlı sistem üzerinde kullanılmıştır.

Sistemin ikinci ana uygulaması olan web tabanlı sunucu uygulaması Java dili ve Java EE çatısı altında MongoDB veritabanı kullanılarak geliştirilmiştir. Reklam süre sayacı olarak belirlenmiş süre içindeki istatistiksel veriler üzerinden baskın olan cinsiyet etiketine ve baskın cinsiyet etiketine sahip kayıtların ortalama uzaklık bilgisine göre kullanıcılara farklı detay seviyelerinde reklamlar sunulmuştur.

Gelecek dönemlerde yapılacak olan çalışmalarda, sisteme eklenebilecek yaş tespit modülüyle birlikte belirli yaş aralıklarındaki görüntüler için ekstra çalışma yapılması amaçlanmaktadır. Ayrıca yüz algılama sınıflandırıcısına ek kontroller eklenerek cinsiyet tespit başarıml yüzdesinin artırılması düşünülmektedir. Cinsiyet tespitine yüz algılama sınıflandırıcısı tarafından iletilen görüntülerde yüzün belirli bir kısmının kapalı veya görünmediđi kayıtlarda, güneş gözlüğü, şapka ve benzeri ekipman kullanan görüntüler üzerinde ön işleme çalışması yapılarak cinsiyet tespitinin daha başarılı olması için çalışmalar yapılması planlanmaktadır.

KAYNAKLAR LİSTESİ

- [1] Amscreen introduces digital technology to Tesco UK petrol station network, <http://www.amscreen.eu/amscreen-introduces-digital-technology-to-tesco-uk-petrol-station-network-2/> (Son erişim: 31 Mayıs 2018), 29 Ekim 2013.
- [2] A first in Turkey; different campaigns according to age and gender, <https://www.odeabank.com.tr/en-us/about-odeabank/press-releases/sayfalar/a-first-in-turkey-different-campaigns-according-to-age-and-gender.aspx> (Son erişim: 31 Mayıs 2018), 26 Kasım 2015.
- [3] Makinen, E., Raisamo R., An experimental comparison of gender classification methods, *Pattern Recognition Letters*, cilt 29, no. 10, pp. 1544-1556, 2008.
- [4] Viola, P. A., Jones M. J., Robust Real-Time Face Detection, *Int J Comput Vision*, cilt 57, no. 2, pp. 137-154, 2004.
- [5] OpenCV Documentation Cascade Classification: Haar Feature-based Cascade Classifier for Object Detection, https://docs.opencv.org/2.4/modules/objdetect/doc/cascade_classification.html. (Son erişim: 28 Haziran 2018).
- [6] Özcan, S.R., Tavşanoğlu, V., Taşıtlarda Hog Temelli Gömülü Yaya Belirleme Sistemi Tasarımı ve Gerçeklemesi, *Otomotiv Teknolojileri Kongresi*, Bursa, 2014.
- [7] Karakaya, F., Altun, H., Çavuşoğlu, A., Gerçek Zamanlı Nesne Tanıma Uygulamaları için HOG Algoritmasının FPGA Tabanlı Gömülü Sistem Uyarlaması, *IEEE 17th Signal Processing and Communications Applications Conference*, Kocaeli, 2009.
- [8] Dalal, N., Triggs B., Histograms of oriented gradients for human detection, *Int. Conf. on Comp. Vision and Pattern Rec.*, cilt 2, pp. 886-893, 2005.
- [9] Dalal, N., Triggs B., Schmid, C., Human Detection Using Oriented Histograms of Flow and Appearance, *9th European Conference on Computer Vision*, Graz, 2006.

- [10] Dalal, N., Finding People in Images and Videos, *Master Thesis, Grenoble Institute of Technology Computer Sciences, Applied and Pure Mathematics*, Grenoble, 2006.
- [11] Turk, M., Pentland, A., Face recognition using eigenfaces, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Maui, 1991.
- [12] Du, Y., Lu, X., Chen, W., Xu, Q., Gender recognition using fisherfaces and a fuzzy iterative self-organizing technique, *Fuzzy Systems and Knowledge Discovery (FSKD)*, Shenyang, 2013.
- [13] APAYDIN Ethem, Introduction to Machine Learning 3rd. ed., The MIT Press, ISBN:978-0-262-02818-9, 2014.
- [14] Peter, M., Dmitry, M., Analysis of Gender Recognition Methods, *ICICIP'14*, Dalian, 2014.
- [15] Wikipedia, https://en.wikipedia.org/wiki/Support_vector_machine (Son erişim: 28 Haziran 2018).
- [16] Quora, <https://www.quora.com/What-is-the-relation-between-SVM-kernels-and-CNN-kernels> (Son erişim: 28 Haziran 2018).
- [17] Shan, C., Learning local binary pattern for gender classification on real world face images, *Pattern Rec. Letters*, cilt 33, no. 4, pp. 431-437, 2012.
- [18] Singh, V., Shokeen, V., Singh, B., Comparison of Feature Extraction Algorithms For Gender Classification From Face Images, *International Journal of Engineering Research & Technology (IJERT)*, cilt 2, no. 5, 2013.
- [19] Krizhevsky, A., Sutskever, I., Hinton, E.G., ImageNet classification with deep convolutional neural networks, *25th International Conference on Neural Information Processing System*, cilt 1, pp. 1097-1105, 2012.
- [20] İnik, Ö., Ülker, E., Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpasa Journal of Scientific Research*, cilt 6, pp. 85-104, 2017.
- [21] Kurt, F., Derin Ogrenme, <http://www.derinogrenme.com/category/sunumlar/> (Son Erişim: 31 Mayıs 2018), 28 Kasım 2016.

- [22] Lee, C. S., Wang, M. H., Yen, S. J., Wei, T. H., Wu, I-C., Chou, P. C., Chou, C. H., Wang M. W., Yan, T. H., Human vs. Computer Go: Review and Propect, *IEEE Comput. Intell. Mag.*, cilt 11, pp. 67-72, 2016.
- [23] Song, H. A., Lee, S. Y., Hierarchical Representation Using NMF, *International Conference on Neural Info. Processing* , pp. 466-374, 2013.
- [24] Cun, Y. Le, Handwritten digit recognition: applications of neural network chips and automatic learning, *IEEE Commun. Mag.*, cilt 27, no. 11, pp. 41-46, 1989.
- [25] Levi, G., Hassner, T., Age and Gender Classification using Convolutional Neural Networks, *Computer Vision and Pattern Recognition Workshops*, Boston, 2015.
- [26] Lecun, Y., Bengio, Y., Hinton, G., Deep Learning, *Nature Publishing Group Country of Publication*, pp. 436-444, 2015.
- [27] Grefenstette, E., Blunsom, P., N. de Freitas, Hermann, K. M., A Deep Architecture for Semantic Parsing, <https://arxiv.org/pdf/1404.7296v1.pdf> (Son erişim: 5 Haziran 2018), 29 Nisan 2014.
- [28] Shen, Y., He, X., Gao, J., Deng, L., and G. Mesnil, Learning semantic representations using convolutional neural networks for web search, *23rd International Conference on World Wide Web*, Seoul, 2014.
- [29] Kalchbrenner, N., Grefenstette, E., Blunsom, P., A Convolutional Neural Network for Modelling Sentences, *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics*, pp. 655-665, 2014.
- [30] Şeker, A., Diri, B., Balık H., Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi*, cilt 3, no. 3, pp. 47-64, 2017.
- [31] Adler, A., Elad, M., Zibulevsky, M., <http://arxiv.org/abs/1610.09615> (Son erişim: 5 Haziran 2018), 30 Ekim 2016.
- [32] Doğan, F., Türkoğlu, İ., Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, *Sakarya University Journal of Computer and Information Sciences*, cilt 1, pp. 10-21, 2018.
- [33] Cheng, F. Y., Chang, C. J., Jong, G.J., Digital Interactive Kanban Advertisement System Using Face Recognition Methodology, *Computational Water, Energy, and Environmental Engineering*, cilt 2, pp. 26-30, 2013.

- [34] Chen, D. Y., Lin, K. Y., A Novel Viewer Counter For Digital Billboards, *Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, Kyoto, 2009.
- [35] Zhang, H., Wang, S., Cao, X., Yue, H., Wang, K., Learning to Link Human Objects in Videos and Advertisements with Clothes Retrieval, *International Joint Conference on Neural Networks*, Vancouver, 2016.
- [36] Labeled Faces in the Wild (LFW), <http://vis-www.cs.umass.edu/lfw/> (Son Eriřim: 31 Mayıs 2018).
- [37] OpenU, https://www.openu.ac.il/home/hassner/projects/cnn_agegender/ (Son eriřim: 31 Mayıs 2018), 5 Mayıs 2015.
- [38] GilLevi, <https://github.com/GilLevi/AgeGenderDeepLearning> (Son eriřim: 31 Mayıs 2018), 30 Ekim 2015.
- [39] Dlib, <http://dlib.net/> (Son eriřim: 31 Mayıs 2018).
- [40] D.King, Dlib, <http://blog.dlib.net/2014/02/dlib-186-released-make-your-own-object.html> (Son eriřim: 31 Mayıs 2018), 3 řubat 2014.
- [41] Youtube, Panasonicsecurity, <https://www.youtube.com/watch?v=TS0TiZwuxC8> (Son eriřim: 31 Mayıs 2018), 5 Haziran 2012.
- [42] Youtube, <https://www.youtube.com/watch?v=LsK0hzcEyHI> (Son Eriřim: 5 Haziran 2018), 8 Ocak 2014.
- [43] Belhumeur, P. N., Hespanha, J. P., Kriegman, D. J., Eigenfaces vs. Fisherfaces: recognition using class specific linear projection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, cilt 19, no. 7, pp. 711-720, 1997.
- [44] Ayhan, S., Erdoęmuř, ř., Destek Vektör Makineleriyle Sınıflandırma Problemlerinin řözümü için řekirdek Fonksiyonu Seçimi, *Eřiřehir Osmangazi Üniversitesi İİBF Dergisi*, cilt 9, no. 1, pp. 175-198, 2014.
- [45] Szegedy, C., Liu, W., Jia, Y. Q., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich A., Going Deeper with Convolutions, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 2015.

- [46] Nguyen, A., Head Circumference in Canadian Male Adults: Development of a Normalized Chart, *International Journal of Morphology*, cilt 30, no. 4, p. 1474–1480, 2012.
- [47] Wikipedia, https://en.wikipedia.org/wiki/Human_head (Son Erişim: 5 Haziran 2018).
- [48] Laia, MathWorks, <https://in.mathworks.com/matlabcentral/fileexchange/32271-distance-measure-from-object-to-camera> (Son Erişim: 31 Mayıs 2018), 20 Temmuz 2011.
- [49] Rosebrock, A., Find distance from camera to object/marker using Python and OpenCV, <https://www.pyimagesearch.com/2015/01/19/find-distance-camera-objectmarker-using-python-opencv/> (Son Erişim: 31 Mayıs 2018) , 19 Ocak 2015.
- [50] Data Vision, <https://data.vision.ee.ethz.ch/cvl/rrothe/imdb-wiki/> (Son Erişim: 31 Mayıs 2018).
- [51] Vision & Interaction Group, <http://vintage.winklerbros.net/facescrub.html> (Son Erişim: 31 Mayıs 2018).
- [52] Qt Wiki, <https://wiki.qt.io/Main> (Son Erişim: 31 Mayıs 2018).
- [53] Qt, https://download.qt.io/official_releases/qt/5.7/5.7.0/, (Son Erişim: 31 Mayıs 2018), 15 Haziran 2016.
- [54] Nvidia, <https://developer.nvidia.com/deep-learning-frameworks>, (Son Erişim: 31 Mayıs 2018).
- [55] Yangqing Jia, Y., Evan S., Caffe Berkeley Vision, [\http://caffe.berkeleyvision.org/installation.html, <https://github.com/lrtaI/caffe-gpu-installation> (Son Erişim: 31 Mayıs 2018).
- [56] Nvidia, <http://www.nvidia.com.tr/object/cuda-parallel-computing-tr.html> (Son Erişim: 31 Mayıs 2018).
- [57] Github, <https://github.com/BVLC/caffe.git> (Son Erişim: 31 Mayıs 2018).
- [58] Uçar, A., Bingöl, M. S., Derin öğrenmenin Caffe kullanılarak grafik işleme kartlarında değerlendirilmesi, *DÜMF Mühendislik Dergisi*, pp. 39-49, 2018.

- [59] Caffe: Convolutional Architecture for Fast Feature Embedding, <https://arxiv.org/pdf/1408.5093.pdf> (Son Eriřim: 5 Haziran 2018), 20 Haziran 2014.
- [60] John R. Jensen, Ryan R. Jensen, Introductory Geographic Information Systems, Pearson Press, ISBN:978-0-13-302953-6, 2013.