

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

**BİLGİSAYAR GÖRMESİNE DAYALI VE
EVRİŞİMSEL SİNİR AĞLARI KULLANARAK YAŞ
VE CİNSİYET TAHMİNİ**

YÜKSEK LİSANS TEZİ

Zineb FATHI

**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**
Tez Danışmanı : Dr. Öğr. Üyesi Serap KAZAN

Eylül 2020

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Zineb FATHI

11.09. 2020

TEŞEKKÜR

Yüksek lisans eğitimim boyunca ve tez çalışmamın her aşamasında yönlendirmeleri, tez konumu belirlemede ve çalışmalarım sırasında fikirlerini ve bilgilerini paylaşan ve tavsiyeleri ile bana ışık tutan değerli danışman hocam Dr. Öğr. Üyesi Serap KAZAN'a sonsuz teşekkürler.

Ayrıca yaşamım boyunca arkamda duran, eğitim hayatımda kendilerinden aldığım destek ile bir adım ileriye gitmekte güç bulduğum annem Souad GRAOUI babam Mustapha FATHI en özel teşekkür ve şükran duyguları ile.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ.....	viii
ÖZET	ix
SUMMARY	x
BÖLÜM 1.	
GİRİŞ.....	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	4
2.1. Cinsiyet Tahmin Yaklaşımı.....	4
2.2. Yaş Tahmini Yaklaşımı.....	7
2.3. Hem Cinsiyet Hem De Yaş Tahmin Yaklaşımları	9
2.4. Özet	12
2.5. Cinsiyet Tahmini	12
2.6. Yaş Tahmini	13
BÖLÜM 3.	
METODOLOJİ	14
3.1. Ön İşleme	15
3.2. Transfer Öğrenme Kavramının Gözden Geçirilmesi	16
3.3. Motivasyon.....	16
3.4. Transfer Öğrenmeyi Anlama.....	17

3.5. Formal Tanımlama	18
3.6. Önemli Çıkarımlar.....	19
3.7. Öğrenme Stratejilerini Aktarma	19
3.8. Önceden Eğitilmiş Modeller	22
3.9. Yaş ve Cinsiyet Sınıflandırması İçin CNN	22
3.10. Veri setleri	23
3.10.1. IMDB-WIKI veritabanı.....	23
3.10.2. FG-NET veritabanı.....	23
3.10.3. Adience veritabanı.....	24
3.10.4. UTKFace veritabanı	24
3.10.5. Veri setlerimizin yaş dağılımı	25
3.11. Sıfırdan Basit CNN Modeli.....	25
3.12. InceptionV3 Mimarisinin Gözden Geçirilmesi	26
3.13. MobilNetV2 Modelinin Gözden Geçirilmesi.....	27
3.14. SSR-Net Gözden Geçirilmesi.....	28
3.15. Özet	29

BÖLÜM 4.

UYGULAMA VE SONUÇLAR	30
4.1. Sonuçlar.....	31
4.2. Değerlendirme	33
4.3. Eğitim Parametreleri.....	33
4.3.1. FGNET dataset.....	34
4.3.2. UtkFace dataset	34
4.4. Transfer Öğrenmesinin Avantajları.....	35
4.5. Transfer Öğrenme Zorlukları	36
4.6. Sonuç ve Gelecek Çalışmalar.....	37
4.7. Çıkarım süresi - Performans Puanı.....	37
4.8. Web'den gerçek zamanlı yaş ve cinsiyet tahmini.....	38
4.9. Sonuçlar.....	39

BÖLÜM 5.

SONUÇ VE GELECEK ÇALIŞMALAR	41
5.1. Sonuç	41
5.2. Gelecek Çalışmalar.....	42
KAYNAKLAR	43
ÖZGEÇMİŞ	51



SİMGELER VE KISALTMALAR LİSTESİ

ANN	: Artificial Neural Networks- Yapay Sinir Ağları
APM	: Appearance Model- Görünüm Modeli
BIF	: Biologically Inspired Features- Biyolojik İlham Özellikler
CDF	: Cumulative Distribution Frequency- kümülatif Dağılım Sıklığı
CH	: Color Histogram- Renk Histogramı
CM	: Confusion Matrix- Karışıklık Matrisi
CNN	: Convolutional Neural Network- Evrimsel Sinir Ağları
CS	: Cumulative Score- Kümülatif Puan
DCT	: Discrete Cosine Transformation- Ayrık Kosinüs Dönüşümü
EBPC	: Exploratory Basis Pursuit Classification- Keşfedici Temel Sınıflandırma
FFH	: Feature Fusion Hierarchies- Özellik Füzyon Hiyerarşileri
GA	: Genetic Algorithm- Genetik Algoritma
GMM	: Gaussian Mixture Model- Gaussian Karışım Modeli
GWT	: Gabor Wavelet Transformation- Gabor Dalgacık Dönüşümü
HE	: Histogram Equalization- Histogram Eşitleme
HOG	: Histograms of Oriented Gradients ICA Independent Component Analysis
KFDA	: Kernel Fisher Discriminant Analysis- Çekirdek Fisher Ayrımcı Analizi
LCP	: Local Circular Patterns- Yerel Dairesel Kalıplar
LDA	: Linear Discriminant Analysis- Doğrusal Ayırım Analizi
LEA	: Locally Embedded Analysis- Yerel Gömülü Analiz
LFW	: Labelled Faces in the Wild
LOO	: Leave-One-Out Cross-validation- Tek Başına Ayrılma Doğrulaması
MAE	: Mean Absolute Error- Ortalama Mutlak Hata

PCA	: Principal Component Analysis- Temel bileşenler Analizi
SFP	: Spatially Flexible Patch- Mekansal Esnek Yama
SIFT	: Scale-Invariant Feature Transform- Ölçek Değişmeyen Özellik Dönüşümü
SOM	: Self-Organizing Map- Kendini Düzenleyen Harita
SSR-NET	: Compact Soft Stageswise Regression Network
SVM	: Support Vector Machine- Destek Vektör Makinesi
RPK	: Patch Kernel- çekirdeğine yama
RBF	: Radial Basis Function- Radyal Temel İşlevi
WLD	: Weber's Local Descriptor- Weber'in Yerel Tanımlayıcı
YGA	: YAMAHA Gender and Aging Database- YAMAHA Gender and Aging verikumesi

ŞEKİLLER LİSTESİ

Şekil 3.1. Cinsiyet ve Yaş Tahmin Sistemi Genel Metodolojisi	15
Şekil 3.2. Geleneksel öğrenimi vs. transfer öğrenimi.....	18
Şekil 3.3. IMDB ve WIKI veritabanından bir örnek	23
Şekil 3.4. FG-NET veritabından bir örnek	24
Şekil 3.5. Adience veritabından bir örnek	24
Şekil 3.6. UTKFace veritabından bir örnek.....	25
Şekil 3.7. Kullanılan veritabanlarının yaş dağılımı	25
Şekil 3.8Wikipedia'dan tipik bir CNN modeli	26
Şekil 3.9. Inception V3'ün şematik diyagramı.....	27
Şekil 3.10. SSR-Net'in şematik diyagramı.....	28
Şekil 3.11. Dönemlerin sayısına karşılık tanıma hatalarının grafiği.....	29
Şekil 4.1. Öğrenme oranının Kayıp Üzerine Etkisi	30
Şekil 4.2. Kullanılan modellerden birinin sonuçlarına bir örnek.....	31
Şekil 4.3. SSR-Net model 'in Dönem vs Kayıp Grafikler.....	32
Şekil 4.4. InceptionV3'in Dönem vs Kayıp Grafikler	32
Şekil 4.5. MobileNetV2'in Dönem vs Kayıp Grafikler.....	32
Şekil 4.6. FG NET veri kümesi için ortalama MAE değerleri.	34
Şekil 4.7. UTKFace veri kümesi için ortalama MAE değerleri.....	34
Şekil 4.8. UTKFace veri kümesi için ortalama MAE değerleri.....	35
Şekil 4.9. Docker ve nvidia docker AGX platformu kullanarak eşzamanlılık	37
Şekil 4.10. Gerçek zamanlı yaş ve cinsiyet tahmini	39

TABLÖLAR LİSTESİ

Tablo 2.1. Ortak cinsiyet tahmini yöntemleri	12
Tablo 2.2. Ortak yaş tahmin yöntemleri	13
Tablo 3.1. Transfer Öğrenme Stratejilerinin Türleri ve Ayarları	20
Tablo 3.2. Öğrenme Stratejilerini ve Aktarılabılır Bileşen Türlerini aktarma.....	22
Tablo 4.1. Ort MAE çözümü	33

ÖZET

Anahtar kelimeler: Evrişimsel Sinir Ağları, MobileNet V2, Inception V3, SSR-Net mimarisi.

İnsan yüzü; ifade, etnik kimlik, cinsiyet ve yaş gibi, kişi hakkında çok önemli niteliklere ve bilgilere sahiptir. İnsanoğlu bu bilgileri kolayca tespit edip analiz edebilir; örneğin insanların çoğu cinsiyet gibi insan özelliklerini kolayca tanıyabilir, kişinin sadece yüzünü görerek kadın ya da erkek olup olmadığını söyleyebilir. Aynı şekilde, kişinin yaşını belirleyebilir ve bu kişinin çocuk mu yoksa yetişkin mi olduğunu belirleyebilir. Öte yandan, insanları yüzlerinden tanımlamak, yaş ve cinsiyet bilgilerini çıkarmak için uygulamalar oluşturmak, modern dünyanın ihtiyaçları nedeniyle günlük hayatımızın birçok önemli alanında bağımlı olduğumuz bilgisayar vizyonu için zorlu bir görevdir.

Bu çalışma, insanların yüzlerinden yaş ve cinsiyet tahminine yönelik derin bir öğrenme çözümüne odaklanmaktadır. Evrişimsel Sinir Ağları (CNN-Convolutunel Neurel Network) kullanarak IMDB-Wiki Veri Kümesi'nden transfer öğrenme ve ince ayar gerçekleştirilmektedir. İlk olarak, transfer modeli üç model olarak kullanılmıştır: Birinci model: Eğitilmesi daha hızlı olan ve görüntü sınıflandırması için kullanılan ImageNet veri kümesi ile önceden eğitilmiş olan MobileNet V2 modeli. İkinci model: Bir CNN türü olan Inception V3 modeli. Bu model Birçok evrişim ve maksimum havuzlama katmanından oluşur. Her iki model de Keras uygulamasıdır. Ve son model bazı değişiklikleri kapsayan SSR- Net mimarisidir.

AGE AND GENDER PREDICTION USING MACHINE LEARNING

SUMMARY

Keywords: machine learning, convolutional neural network, inceptionv3, mobilenetv2, SSR-Net

There are considerable quantities of available data about a person like human face such as age, gender, ethnic background and facial expressions). Humans can easily identify and analyze this information, for example, most people can recognize human characteristics, such as gender, where they can only see their face and tell if they are men or women. In the same context, they can figure out someone's age including determining if this person is still a child or became an adult. Additionally, it is challenging for the computer to build applications that could recognize people's faces and determine their age and gender in which the modern world will depend on many important aspects of our daily life to create a general model that fits all humans.

This study focuses on a deep learning solution for predicting age and gender from people's faces. We perform transfer learning and fine tuning from the IMDB-Wiki Dataset using Convolutional Neural Networks (CNN). First, we use the transfer model using three models: the MobileNet V2 model, which is faster to train and is pre-trained with the ImageNet dataset for image classification. The second model, Inception V3 it consists of many convolution and maximum pooling layers. Both models are from Keras application. And we follow the SSR-Net architecture, which is the default for the latest training, with some change.

BÖLÜM 1. GİRİŞ

Otomatik yüz sınıflandırma sistemlerinin çoğu bilgisayar görmesi ve örüntü tanıma üzerine kuruludur. Bilgisayar görmesi, görüntülerden bilgi anlama, analiz etme ve çıkarma yöntem ve tekniklerini içerir. Başka bir deyişle, bilgisayarın dünyamızı görmesini ve tanımlamasını sağlayan bir sistem kurmaya çalışan bir bilimdir. Öte yandan örüntü tanıma, konuşma sinyalinin, parmak izi görüntüsünü, el yazısıyla yazılmış bir kelimeyi, ortamı veya bir insan yüzü olabilen deseni makinaların nasıl tanıyabildiğini ve algılayabildiğini tanımlayan ve yorumlayan bir teknolojidir. Örüntü tanıma sisteminin tasarımı, ön işleme, özellik çıkarma ve sınıflandırma olmak üzere üç ana bölümden oluşur. Ön işleme ve veri toplama kısmı, uygun bir veritabanı seçmek, örnekleri normalleştirmek, gereksiz olanları izole etmek, eğitmek ve test setlerine bölmekle ilgilidir. Bu kısımda ayrıca görüntüyü yeniden boyutlandırma, segmentasyon, ışıktandırmaların değiştirilmesi veya diğer düzeltmeler gibi bazı görüntü modifikasyonları ile görüntülerin görünüşleri iyileştirilebilir. Özellik çıkarma kısmı ise; iyi özellikler bulmak, desen sınıflarını ve gösterimi tanımlamak ve bu özellikleri ölçerek verileri azaltmakla ilgilidir. Sınıflandırma kısmı, bir sınıflandırıcının özellik alanını bölgelere böldüğü ve bir kategoriye bir desen atadığı çok kritik bir kısımdır. Ayrıca, sistemin performans, hız, doğruluk ve maliyete dayalı olarak değerlendirilmesiyle ilgilenen, değerlendirme adı verilen isteğe bağlı dördüncü bir kısım bulunmaktadır.

Bilgisayar görmesi ve örüntü tanıma 1970'lerden bu yana aktif bir araştırma alanıdır. Hayali görüntülerden yaş ve cinsiyet tahmini son zamanlarda incelenmiştir. Bu tezde iki bilgisayar görme problemi çalışılmaktadır: Cinsiyet sınıflandırması ve yaş tahmini.

Yüz görüntülerinden cinsiyet tahmin etmek ilgi çekici bir araştırma konusu ve bilgisayar için önemli bir görevdir ancak gereksinimler ve mevcut performanslar

arasında bir eksiklik vardır. Bu eksiklik, aydınlatma, çözünürlük, ifade vb. çeşitlilik nedeniyle artar. Yüz görüntülerinden cinsiyet tahmini, insan-bilgisayar etkileşimi, müşteri bilgileri ölçümü ve erişim kontrolü gibi çok sayıda uygulamanın performansını artırabilir. Dahası, güvenlik sistemleri, biyometrik kimlik doğrulama, tıbbi görüntüleme sistemleri, gözetim sistemleri arayüzleri ve içerik tabanlı arama gibi birçok alanı önemli ölçüde etkileyebilir. Cinsiyet tahmini sorununa bir çözüm bulmak için, mevcut yöntemlerin çoğu sadece yüz sınıflandırma yöntemlerine bağlıdır.

İnsan ve bilgisayar etkileşimi, güvenlik sistemleri ve görsel gözetim gibi birçok bilgisayar görme uygulaması için önemli modülleri ve faydalı kullanımları nedeniyle yaş ve cinsiyet tahmin sistemleri hızla büyümektedir. Cinsiyet ve yaş tahmininin önemini gösteren birçok örnek vardır. Örneğin, alkol almak, araç kullanmak, yurtdışında yalnız seyahat etmek, sigara içmek, vb. için belirli bir yaş sınırı vardır. Ancak sorun, insan tahmini yaş becerilerinin sınırlı ve doğru olmamasıdır. Bu nedenle, bilgisayar görme sistemleri, yaşların tam doğru tahmin edilmesinde yardımcı olacaktır. Bir başka örnek de terörist tehditlerin artmasının ardından, havaalanlarının yolcuların cinsiyet bilgilerini otomatik olarak toplamak için güvenlik kontrol noktalarındaki güvenlik önlemlerini artırmalarıdır.

Bu tezde iki ayrı problem incelenecektir: cinsiyet sınıflandırması ve yüz görüntülerinden yaş tahmini. Bu nedenle, asıl zorluğumuz, çeşitli özellik çıkarıcılarını kullanarak ve birleştirerek yüksek doğruluk sağlayabilen ve doğru cinsiyet sınıflandırması ve yaş tahmini sistemleri için bir yöntem, tasarım ve uygulanma önermektir.

Yüz görüntülerinden bireylerin yaşını ve cinsiyetini tahmin etmeye odaklanan birçok uygulama ve çalışma vardır. Ancak, birçok engel yanlış sonuçlara yol açabilir. Örneğin, yüz görüntülerinin aydınlatılması, kısıtsız ortamlar, kafa pozu, yüz ifadesi, görüntü arka planı, görüntü boyutları, gölgeler, kalite, ten rengi vb. Bu nedenle, sistem yüz görüntülerinin fotometrik özelliklerini standartlaştırmalı ve normalleştirmeli ve daha fazla yüz ayırt etmeye izin veren en açıklayıcı özellikleri çıkarmalıdır. Sonuç olarak, bu veriler yüzün cinsiyetini ve yaş kategorisini tahmin etmek için kullanılır.

Bu tez, insanların yüz görüntülerinden cinsiyet ve yaş tahmin etme performansını ve doğruluğunu artırmayı amaçlamaktadır. Keras'tan iki sınıflandırıcıımız bulunmaktadır -Python Deep Learning kütüphanesi- Cinsiyet sınıflandırıcısı biri erkek diğeri kadın için iki ayrı çıktı halinde sınıflandırabilmelidir. Oysa yaş sınıflandırıcısı 101 çıkışıdır (0-100 yaşını temsil eder). Yaş tahmini, [] referansındaki gibi softmax regresyonundan hesaplanan çıktısıyla çok sınıflı sınıflandırma problemi olarak ele alınmıştır.

Bu çalışmaya bilgisayar vizyonu çerçevesinde yaş ve cinsiyet tahmin sistemleri hakkında genel bilgi ve genel fikir vererek, bunların önemini gözden geçirerek ve yaş ve cinsiyet tahmin sistemi geliştirirken karşılaşılabileceğimiz olası sorunları tartışarak başlanmıştır. 2. Bölümde, yaş ve cinsiyet sınıflandırması alanındaki bazı literatür incelemelerini ve ilgili çalışmaları gözden geçirilmiştir. Bölüm 3'te bu tezin özü ve yöntemi açıklanmıştır; öncelikle yüz özelliklerinin çıkarılması için kullanılan üç temel tekniğin genel bir açıklaması gözden geçirilmiştir. Bu teknikler, inceptionv3, mobilenetv2 ve SSR-net sınıflandırıcılarıdır. Ayrıca, sınıflandırıcıların performansını eğitmek ve değerlendirmek için kullanılan değerlendirme tekniklerine kısa bir bakış verilmiştir. Ardından, bu tezde kullanılan veritabanlarına genel bir bakış sunarak 3. Bölüm bitirilmiştir. 4. Bölümde, sınıflandırıcının yüksek doğrulukta performans elde etmesini sağlamak için birçok kapsamlı deney yapılmıştır. Cinsiyet ve yaş tahmin sistemlerinin doğruluğunu ve performansını arttırmak için yüz görüntülerinin boyut hizalaması ve aydınlatma normalizasyonu ve özellik çıkarıcılarının birleştirilmesi konusundaki iyileştirmeler uygulanmıştır. Ayrıca, sistemlerimizin performansı MAE and e-error teknikleri kullanılarak değerlendirilmiştir. Daha sonra, bu bölüm önerilen deneylerin en doğru sonuçlarını sunarak bitirilmiştir. Son olarak, Bölüm 5 bu tezin en önemli noktalarını sonuçlandırmakta ve özetlemekte, gelecekteki çalışmaları ve yaş ve cinsiyet sınıflandırma sistemlerinin performansını artırmak için olası stratejileri göstermektedir.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Cinsiyet Tahmin Yaklaşımı

Burada, yüz ve yürüyüş tarzına dayalı iki kategoride gruplanan çeşitli cinsiyet tahmini yaklaşımları genel olarak incelenmiştir. Yüz tabanlı yaklaşımlar bir yüz algılama fazı veya yüz özelliklerini çıkarmak için yüz görüntüleri kullanırken yürüyüş temelli yöntemler ise cinsiyeti tahmin edip tüm vücudun özelliklerini çıkarmak için insan algılama algoritmalarına ihtiyaç duyar [7, 8]. Ancak bu tezde sadece görünüş temelli ve özellik temelli metodlar şeklinde ikiye ayrılabilen yüz temelli metodlara odaklanılmıştır.

Yüz görüntülerinden cinsiyet bilgilerinin belirlenmesi, bilgisayarla görmesi alanında uzmanlaşmış birçok araştırmacının ilgisini çekmiştir. Sun ve ark., [5] Genetik Algoritma (GA) kullanarak frontal yüz görüntülerinden cinsiyet tanımanın zorluğunu araştırmışlardır. Temel Bileşen Analizi'ni (PCA) kullanarak özellikleri çıkarmışlar ve daha sonra bu özelliklerin bir alt kümesini seçmek için GA'yı kullanmışlardır. Ayrıca, Bayesian, Sinir Ağı, SVM ve Doğrusal Diskriminant Analizi (LDA) olmak üzere dört farklı sınıflandırıcı kullanmışlardır. Karşılaştırma sonuçları, %95,3 cinsiyet tanıma doğruluğu ile PCA + SVM'nin üstünlüğünü göstermektedir.

Moghaddam ve Yang [6], cinsiyet sınıflandırma doğruluğunu artırmak için Radyal Temel Fonksiyon (RBF) çekirdeğine sahip SVM sınıflandırıcısı uygulamışlardır. Ancak, yöntemleri FERET veritabanından 1.755 yüz görüntüsüne uygulayarak SVM + Gauss RBF çekirdeğinde %96,62 ve SVM + Kübik Polinom çekirdeğinde %95,12 doğruluk elde etmişlerdir. Jian ve Huang [7] bir özellik çıkarma yöntemi olarak Bağımsız Bileşen Analizi (ICA) ve sınıflandırıcı olarak LDA kullanarak cinsiyeti sınıflandırmaya çalışmışlardır. Bu sınıflandırıcıları FERET veri tabanından alınan 500

ön yüz görüntüsünde değerlendirmişlerdir [8, 9]. ICA'nın LDA ile kullanılması %99,3'lük bir doğruluk elde edilmesini sağlar. Costen et al [10] cinsiyet tanınması için seyrek bir sınıflandırıcılar geliştirmişlerdir. Japon Yüz Görüntüleri Veritabanından alınan 300 görüntünün yüz özelliklerini çıkarmak için PCA kullanmışlardır. Ayrıca, bu verileri üç sınıflandırıcı kullanarak sınıflandırmışlardır: LDA, Keşif Bazlı Takip Sınıflandırma (EBPC) ve SVM. Sınıflandırma sürecinde 10 kat çapraz geçerlilik esası uygulanmış ve daha sonra PCA + LDA, PCA + EBPC, PCA + SVM'de sırasıyla %79,75, %94,25, %94,42 doğruluk elde edilmiştir. Sun ve arkadaşları [11], cinsiyet tanıma için FERET veri tabanındaki görüntülerin özelliklerini çıkaran LBP [12] kullanmışlardır. Ayrıca, deneylerinde hem Kendini Düzenleyen Harita (SOM) hem de eşik Adaboost sınıflandırıcıları kullanmışlardır ve %95,75 tanıma oranı elde etmişlerdir. Benzer şekilde Lian ve Lu [13], SVB sınıflandırıcısı ile LBP özelliklerini uygulamıştır ve %96,75 cinsiyet tanıma oranı bildirmişlerdir.

Makinen ve Raisamo [3], cinsiyet tahmini yöntemlerini otomatik yüz tanıma ile birleştirerek çeşitli deneyler yapmışlardır. Ayrıntılı olarak, Çok Katmanlı Sinir Ağı ve FERET ve WWW veritabanları üzerinde olan SVM olarak iki sınıflandırıcının sonuçlarını karşılaştırmışlardır. Ayrıca, Arama Tabloları (LUT) Adaboost, Eşik Adaboost, Ortalama Adaboost ve LBP olmak üzere dört özellik çıkarıcısı kullanmışlardır. Sonuç olarak, FERET veritabanında elde ettikleri en iyi sınıflandırma doğruluğunu LUT Adaboost ve Sinir Ağına uygulanarak %91,11 ve WWW veritabanına SVM ile LBP uygulanarak %78,25 doğruluk elde etmişlerdir. Fang ve Wang [14], yüz görüntülerinden cinsiyeti sınıflandırmak için LBP özelliğinin yüksek yoğunluğunu azaltmak için PCA kullanmışlardır. FERET veri tabanında çalışmış ve %92,16 başarı oranına sahip olmuşlardır. Scalzo ve arkadaşları [15], PCA, Gabor ve Özellik Füzyon Hiyerarşileri (FFH) şeklinde olan üç özellik çıkarma yöntemini ve LDA, En Yakın Komşular (NN) SVM şeklinde olan üç sınıflandırıcı üzerinde deneyler yapmışlar ve sonuçlarını karşılaştırmışlardır. Bu sınıflandırıcıları FERET veritabanından 400 görüntü üzerinde değerlendirerek FFH + SVM'de %96,2'lik en iyi doğruluğu elde etmişlerdir. Zafeiriou ve ark. [16] XM2VTS veri tabanından alınan 2.360 görüntüye (1.256 erkek ve 1.104 kadın) RBF çekirdeği ile SVM ve Çekirdek Fisher Diskriminant Analizi (KFDA) uygulamış [17] ve %97,20 cinsiyet sınıflandırma

oranı elde etmişlerdir. Lu ve Shi [18], özelliklerini çıkarmadan önce yüzü üç bölgeye ayırmışlardır. İki boyutlu PCA (2DPCA) özellik çıkarıcı olarak, SVM ise bir sınıflandırıcı olarak kullanılmıştır. Bu yöntemi FERET veri tabanından alınan 800 gri tonlu yüz görüntüsüne uygulayarak 2DPCA + SVM %95,33 cinsiyet tanıma oranı elde etmişlerdir.

Singh ve arkadaşları [19] “HOG + SVM” kullanarak %95,56 başarıyla cinsiyet tahmini yapmışlardır. Ayrıca Indian Face Veritabanından seçilen 300 görüntüye “LBP + SVM” yöntemlerini uygulayarak %89,43 doğruluk oranına ulaşmayı başarmışlardır. Benzer şekilde, Liu ve arkadaşları [20], bu yöntemleri LFW yüz veri tabanına uygulayarak "HOG + SVM" ile %94,38 ve "LBP + SVM" ile %91,43 başarıya ulaşmış ve daha sonra "HOG & LBP" yi birleştirmiş ve kullanmışlardır. SVM ile %94,88 cinsiyet tahmini doğruluğuna ulaşmıştır. Luis Alexander [21], FERET ve UND veritabanlarında cinsiyet tanımı için SVM'li LBP'yi kullanılmıştır. Elde edilen en iyi sonuç %93,46 olmuştur. Lin ve Zhao [22] renk bilgisine dayanan bir cinsiyet tanıma şeması üzerinde çalışmışlardır. SVM'yi bazı renk özellikleriyle birleştirerek bir göz algılama algoritması geliştirmişlerdir.

SVM sınıflandırıcısını bu özelliklerle birleştirerek, %80,7 ile cinsiyet tahmin şeması doğruluğu elde etmişlerdir. Shan [23], Adaboost ve SVM sınıflandırıcılarına sahip LBP özellik çıkarıcı kullanarak cinsiyet tanımayı araştırmışlardır. Bu yöntemin sonucu, Wild (LFW) veritabanındaki Etiketli Yüzlerde %94,81 başarı tanıma oranı elde edilmesidir [24]. Ihsan Ullah ve ark. [25] Weber'in Yerel Tanımlayıcısını (WLD) cinsiyet tanıma açısından araştırmışlardır. Teknikleri, bir görüntüyü birkaç bloğa bölmeye, her blok için WLD histogramını hesaplamaya ve bunları bir Mekansal WLD tanımlayıcı (SWLD) oluşturmak için birleştirmeye dayalıdır. (Chi-Square) tekniği ile (%99.08) genel doğruluk elde etmişlerdir. Chen Wang ve ark. [26], cinsiyet sınıflandırması için geleneksel LBP'nin iyileştirilmesi olan ve Yerel Dairesel Desenler (LCP) olarak adlandırılan bir yöntem önermişlerdir [12]. Deneyleri FERET veri tabanında yapılmıştır [8, 9]. Daha sonra hem LBP hem de LCP özellikleri farklı ölçekler için çıkarılmıştır.

Sınıflandırma için doğrusal çekirdekli SVM kullanılmıştır. Sonuç olarak, cinsiyet sınıflandırmasının doğruluğu %95,36'ya kadar çıkmış ve LCP yönteminin etkinliğini açıkça vurgulamıştır. Min Li ve ark. [27], cinsiyet tanınması için insan vücudunun baş kısmını temsil etmek üzere HOG, LBP ve Gabor tanımlayıcıları olmak üzere üç yöntemi bir araya getirmişlerdir. Sonuç olarak, %88,55'lik bir doğruluk elde edilmiştir. Emon Dey ve ark. [28] yeni bir yaklaşımla yüz görüntülerinden cinsiyet saptamasını tanımlamışlardır. Sistem, görüntünün yüz alanını İlgi Alanına (ROI) göre tespit edebilmekte ve daha sonra Ayrık Kosinüs Dönüşümü'nü (DCT) kullanarak cinsiyeti tespit edebilmektedir. Ayrıca, YG eşleştirme doğruluğunu artırmak için LBP kullanılmıştır. Başlangıçta %70 başarı oranı elde etmişler, ancak Histogram Denkleştirme uygulandıktan sonra oran %78,91'e yükselmiştir. Yukarıdaki detaylandırılan tüm cinsiyet tahmini yöntemlerinin bir özeti Tablo 2.1.'de sunulmaktadır.

2.2. Yaş Tahmini Yaklaşımı

Bu bölümde, yaş grubu sınıflandırması ve gerçek yaş tahmini olmak üzere iki farklı gruba ayrılan birkaç yaş tahmini yaklaşımına genel bir bakış sunulmaktadır. Yaş grubu sınıflandırmasında, yaş aralığı sınıflara ayrılmıştır, her sınıfın bir yıl aralığı vardır. Gerçekten de yaş tahmini çoklu sınıf sorunu dışında cinsiyet sınıflandırmasına çok benzer yapıdadır (çünkü yaş tahmini durumunda 2'den fazla sınıfa ihtiyacımız var. Buna karşılık, cinsiyet tahmini sadece iki sınıfa ihtiyaç duyar: erkek ve kadın). Öte yandan, gerçek yaş tahmininde, görüntünün spesifik ve kesin yaşını vermeye ihtiyaç vardır. Bu da genellikle regresyon yöntemleri veya gerçek yaşı veren sınıflandırma ve regresyonların birleşik yöntemlerine dayalıdır. Bununla birlikte, bu bölüm çok zordur ve bildiğimiz kadarıyla, gömülü platformlarda gerçek yaş tahmini için yapılan bir çalışma yoktur veya çok az çalışma vardır.

Yaş tahmin alanındaki ilk makale 1994 yılında Kwon ve Lobo tarafından yayınlanmıştır [29] ve yüzün gözler, ağız, burun ve çene gibi temel özelliklerini bulmak için Antropometrik Modeller (AM) [6, 30] kullanılarak yaş sınıflandırmasını incelemişlerdir. Ek olarak, bir yılan modeli [33] ile her bir yüzdeki kırışıklıkların

yoğunluğunu belirlemek için bir Görünüm Modeli (APM) [31, 32] de kullanılmıştır. Çalışmaları için 47 yüz içeren bir yüz veritabanı oluşturmuşlar ve daha sonra görüntüleri üç yaş grubuna bölmüşlerdir: bebekler, genç yetişkinler ve orta üstü yetişkinler. Bu görüntüleri sınıflandırmak için, göz-burun, ağızdan çene vb. gibi farklı yüz özelliklerinin mesafelerinden hesaplanan altı oran kullanmış, yaş tahmininin genel sonucunu elde etmek için bu oranları kırıksıklık bilgileriyle birleştirdiler ve sonuçta ve %77 başarı elde etmişlerdir.

Lanitis ve arkadaşları [34] yaş tahmini için Aktif Görünüm Modeli'ni (AAM) [35] kullanmışlardır. PCA kullanarak 0 ila 35 yaş arası 500 görüntünün yüz özelliklerini çıkarmışlardır. Gerçek yaşı tahmin etmek ve verilerin sınıflandırılması için Sinir Ağını benimsemişler ve %94,42 başarı oranıyla yaş tahmini bildirmişlerdir. Guo ve ark. [36] ayrıca AAM'yi 0 ila 69 yaş arasındaki FG-NET [37] veritabanından seçilen 500 yüz görüntüsünün cinsiyetini tahmin etmek için kullanmışlardır. Görüntü özellikleri Yerel Olarak Ayarlanmış Sağlam Regres (LARR) kullanılarak çıkarılmıştır. Ardından, yaşı sınıflandırmak için SVM ve Destek Vektör Regresyonu (SVR) yöntemlerini araştırılmışlardır. Deney sonuçları %94,93 başarı tahmin oranı bildirmiştir. Yan ve arkadaşları [38], her bir görüntüden koordinat noktalarının tahsisini modellemek için Gauss Karışım Modeli'ni (GMM) kullanmışlardır, bu da yerel görünüm bilgisi ve koordinat bilgisi arasında mevcut bağlantıyı göstermektedir. Ayrıca, önemli yüz görüntüleri özelliklerini çıkarmak için PCA, Yerel Olarak Yerleşik Analiz (LEA) [39] ve Alt manifold Senkronize Gömme (SSE) uygulamışlardır.

YAMAHA cinsiyet ve yaşlanma veri tabanından ve FG-NET yaşlanma veri tabanından çıkarılan bilgileri sınıflandırmak için Yama Çekirdeğinden (RPK) Regresyon çerçevesi kullanılmıştır. Bir GMM tarafından modellenen sistemleri, %95.05 yaş tahmini doğruluğu elde etmiştir. Başka bir makalede, Yan ve ark., [40], aynı zamanda yerel görünüm ve konum bilgilerini kodlayan, Mekansal Esnek Yama (SFP) adı verilen yeni bir özellik çıkarıcı sunmuşlardır. SFP ayrıca geometrik yanlış hizalama ve gürültülü piksel sorunlarını ele almak için bir GMM tarafından modellenmiştir. %92,18'lik bir doğruluk elde etmek için deney sonuçlarında YGA veri tabanını kullanmışlardır. Guo ve arkadaşları [41] YGA'nın yüz görüntülerinden yaşları

tahmin etmek için Biyolojik Olarak İlham Alan Özellikler'i (BIF) [42] kullanmışlardır. Verileri sınıflandırmak için SVM kullanarak ve bir defaya mahsus bırakma tekniği uygulayarak, %97,42 yaş tahmininin doğruluğunu elde etmişlerdir. Kanno ve ark. [43], kırışıklıkların yoğunluğunu belirlemek ve yüzlerin bilgilerini çıkarmak için bir APM [31, 32] kullanmışlardır. Sonuç olarak, Yapay Sinir Ağları (YSA) FG-NET yaş veritabanından seçilen 110 yüz görüntüsünün dört yaş grubunu sınıflandırmak için %80 doğruluk elde edilmiştir.

Bauckhage ve arkadaşları [44] yüz görüntülerinden yaş tahmini için doğru ve etkili bir yaklaşım önermişlerdir. HOG, Aralık filtresinin hesaplama histogramlarını ve LBP'yi birleştirmişlerdir. Sistemlerini UTD veritabanı ve FG-Net veritabanı konusunda eğitmişlerdir. Sonuç olarak, ilk denemede, algoritmanın iki görüntüyü doğru şekilde sıralayıp sıralamadığını doğrulamış, böylece %77'lik bir doğruluk elde etmişlerdir. İkinci bir deneyde, aday görüntüleri yüzlerin ön pozuna sabitlemişlerdir. Sonuç olarak, sınıflandırma doğruluğu %85'e kadar iyileştirilmiştir. Shan [45], yüz tahminlerini çıkarmak için LBP [12] ve Gabor gibi aydınlatma-değişmez görünüm özelliğini kullanarak yaş tahminini araştırmışlardır. Yüksek doğruluk elde etmek için Gallagher veritabanını [46] yedi kategoriye ayırmışlardır: 0-2, 3-7, 8-12, 13-19, 20-36, 37-65 ve 66 yaş üstü. Daha sonra, ayırmacı yerel özellikleri sınıflandırmak ve öğrenmek için Adaboost ve SVM kullanılmıştır. Deneyleri birçok sonuç göstermiştir, ancak en iyisi %87,7 başarı oranıyla LBP + SVM dir. Benzer şekilde Ylioinas ve arkadaşları [47], [45] 'te kullanılanla aynı yöntemleri uygulamışlar, ancak Grupların İmajı veritabanına uygulamışlardır. Ayrıca, yaş tahmin doğruluğunu artırmaya çalışmak için LBP özelliklerinden bölgesel histogramlar oluşturmuşlardır. Ancak %87,7 başarı oranı elde etmişlerdir ki bu, aynı doğruluk oranıdır [45]. Yukarıdaki tüm yaş tahmin yöntemlerinin bir özeti Tablo 2.2.'de sunulmaktadır.

2.3. Hem Cinsiyet Hem De Yaş Tahmin Yaklaşımları

Bu bölümde hem cinsiyet hem de yaş tahmini yaklaşımlarını aynı anda inceleyen çeşitli araştırmalara genel bir bakış sunuyoruz. Iga et al. [48] cilt rengi, bıyık, saç vb. görüntü bilgilerini elde etmek için Gabor Dalgacık Dönüşümü (GWT) [49] ile grafik

eşleştirmeyi kullanmışlardır. Softopia Japonya HOIP veritabanından alınan tüm bu bilgiler, alınan 300 yüz görüntüsüne SVM uygulanarak sınıflandırılmıştır. Sonuç olarak, %97,3 cinsiyet sınıflandırma oranı ve %67,4 yaş tahmin oranına ulaşmışlardır. Yang ve Ai [50], ekstrakte edilen LBPH ile bir referans histogram arasındaki Chi kare mesafesini bilmek için LBP özellikli ekstraktör kullanmışlardır. Dahası gerçek Adaboost algoritması, en iyi yerel özellikleri bir dizi öğrenen güçlü bir sınıflandırıcı olarak kullanılmıştır. FERET [8, 9] veritabanından 3.540 yüz görüntüsü ve PIE [51] veritabanından 696 görüntü kullanılarak, %93,30 cinsiyet tahmini ve %92,12 yaş tahmini elde edilmiştir. Guo et al, [52] YGA veri tabanını kullanarak yaş tahmini üzerinde çalışmışlardır. İlk olarak, biyolojik olarak esinlenmiş özellikleri değişik öğrenme teknikleriyle birleştiren yüz temsillerine dayanarak cinsiyetin yaş tahmini üzerindeki etkisini araştırmışlardır. Daha sonra, her yaştan ziyade daha küçük cinsiyet ve yaş grupları kullanarak yaş tahmini üzerinde çalışmışlardır.

Büyük bir veritabanı ve beş farklı yüz temsili kullanma sonuçlarına dayanarak, önceki çalışmalara kıyasla Ortalama Mutlak Hata'yı (MAE) %40'a indirebilmişlerdir. Guo et al. [53] kişinin yaşının cinsiyetini tanıması üzerindeki etkisini araştırmışlardır. Bu nedenle, YGA veritabanından seçilen 8.000 yüz görüntüsüne HOG ve LBP kullanmışlardır. Ayrıca SVM, sınıflandırıcıları öğrenmek için kullanılmıştır. Sonuç olarak, HOG + SVM %96.03 doğruluk verirken, LBP + SVM %94,56 cinsiyet sınıflandırması vermiştir. Buna ek olarak, HOG + SVM %88,65, LBP + SVM %90,53 yaş tahmini vermiştir.

Guo et al [54] büyük ölçekli insan yaşı tahmini ile ilgili bazı problemler ortaya koymuşlardır. Ayrıca, geçiş yarışı ve cinsiyetin tahmin hatası oranını artırabildiğini tespit ettiklerinde, yaş tahmin performansının "geçiş yok" ve "geçiş" arasındaki farklarını incelemişlerdir. Özellikle, sistemlerini 55.000'den fazla yüz görüntüsü içeren MORPH-II [55] adlı büyük bir veritabanında uygulamışlardır. Deneyler için, PCA, Marjinal Fisher Analizi (MFA) [56], Ortogonal Lokasyon Koruma Projeksiyonları (OLPP) [57] ve Lokasyon Duyarlı Diskriminan Analizi (LSDA) [58] kullanılmıştır. Sonuç olarak, %95,56 yaş tahmini ve %100 cinsiyet sınıflandırması doğrulukları rapor edilmiştir.

Shirkey ve Gupta [59], bir insan yüzünün alt bölgelerini tanımlamak için kullanılan dikdörtgen özellikler yöntemine dayanan bir cinsiyet ve yaş tanıma algoritması geliştirdiler ve dolayısıyla bileşen bazında veriler piksel bazlı verilerden dönüştürülebilmişlerdir. Cinsiyet sınıflandırması için %90, yaş sınıflandırması için %85 oranına ulaşmışlardır. Mahalingam ve Ricanek [60] aynı ikizlere göre cinsiyet ve yaşın etkilerini araştırmışlardır. HOG ve LBP olan iyi bilinen iki özellik çıkarma tekniğini kullanmış ve karşılaştırmışlardır [12]. Ayrıca, çalışmalarında ND / WVU [61] veritabanı ve CASTA Twins Face [62] veritabanı olmak üzere iki veri tabanı kullanılmıştır. Bununla birlikte, HOG ve LBP sonuçlarını karşılaştırarak hem cinsiyet hem de yaş sınıflandırmasında HOG'un LBP'den daha iyi bir doğruluk sağladığı görülmektedir; burada cinsiyet sınıflandırmasında %91,42 ve yaş tahmininde %52,17, LBP %82,84 cinsiyet sınıflandırmasında %33,15 yaş tahmininde doğruluk sağlanmıştır. Fazl-Ersi ve ark. [63] yaş ve cinsiyeti tanımak için LBP, Renk Histogramı (CH) ve Ölçek Değişmez Özellik Dönüşümü (SIFT) [64] olmak üzere üç yöntem arasında karşılaştırma yapmışlardır. Dahası, Gallagher yüz görüntüleri veritabanından çıkarılan özellikleri sınıflandırmak için SVM sınıflandırıcısını kullanmışlardır [46].

Sonuç olarak, elde ettikleri en iyi doğruluk, %91,59 cinsiyet tanıma ve %63.01 yaş tahmini bildirilen LBP, CH ve SIFT özelliklerini birleştirmektir. Eidinger ve arkadaşları [65] görüntü özelliklerinin en önemli özelliklerini öğrenmek ve çıkarmak için LBP ve ilgili Dört Yama LBP kodlarını (FPLBP) [66] kullanmıştır. Bu görüntüler Gallagher veritabanından seçilmiştir. LBP ve FPLBP özelliklerini ve SVM'yi birleştirerek, cinsiyet tanınmasının %88,4'ünü ve yaş tahmininin %80,7'sini doğrulamışlardır. Azarmehr ve ark. [40] yaş ve cinsiyet sınıflandırması için tam bir sistem önermişlerdir, bu da kısıtsız koşullar altında bile iyi bir doğruluk sergilemektedir. Yüz temsili için LBP kullanılmıştır. Ek olarak, LDA ve PCA ayrıca yüz özelliklerini çıkarmak için kullanılmıştır. Deneylerinde FERET veritabanından 1.010 görüntü [8, 9], MORPH-II veritabanından 13.000 görüntü [55] ve Gallagher veritabanından 5.080 görüntü olmak üzere üç veritabanından seçilen çok sayıda görüntü kullanılmıştır. Tüm bu verilere SVM sınıflandırıcısı uygulanarak %99,5 cinsiyet sınıflandırması ve %98,8 yaş tahmininde doğruluk elde edilmiştir. Yukarıdaki

tüm yaş ve cinsiyet tahmin yöntemlerinin bir özeti Tablo 2.1. ve Tablo 2.2.'de sunulmaktadır.

2.4. Özet

Bu bölüm, yüz görüntülerinden insanların cinsiyetini ve yaşını tahmin etmek için yapılan çeşitli girişimlere genel bir bakış sunmuştur. Araştırmacılar tarafından sistem performanslarını artırmak ve yüksek doğruluklara ulaşmak için birçok yaklaşım, özellik çıkarma algoritması, veritabanı, sınıflandırıcı, teknik ve yöntem kullanılmıştır. Burada, bu bölümde sunulan en önemli yöntemleri ve veritabanlarını özetlenecek, gözden geçirilecek ve elde edilen doğrulukları karşılaştırılacaktır.

2.5. Cinsiyet Tahmini

Tablo 2.1. Ortak cinsiyet tahmini yöntemleri

Araştırma	Yöntem	Veri tabanı	Görüntü Sayısı	Doğruluk
Azarmehr et al [40]	LBP + SVM	FERET	1,010	99.50%
Jian & Huang [7]	ICA + LDA	FERET	500	99.30%
Iga et al [14]	GWT + SVM	HOIP	300	97.30%
Zafeiriou et al [30]	RBF + SVM	XM2VTS	2,360	97.20%
Lian & Lu [13]	LBP + SVM	FERET	1,040	96.75%
Moghaddam & Yang [6]	RBF + SVM	FERET	1,755	96.62%
Scalco et al [15]	FFH + SVM	FERET	400	96.20%
Guo et al [53]	HOG + SVM	YGA	8,000	96.03%
Sun et al [11]	SOM + Adaboost	FERET	600	95.75%
Sing et al [19]	HOG + SVM	Indian Faces	300	95.56%
Wang et al [26]	LCP + SVM	FERET	1,202	95.36%
Lu & Shi [18]	PCA + SVM	FERET	800	95.33%
Sun et al	PCA + SVM	WWW	400	95.30%
Shan [23]	LBP + Adaboost	LFW	7,443	94.81%
Guo et al [53]	LBP + SVM	YGA	8,000	94.56%
Costen et al [10]	PCA + SVM	Japanese Faces	300	94.42%
Liu et al [20]	HOG+SVM	LFW	5,660	94.38%
Alexander [21]	LBP+SVM	UND	487	93.46%
Yang & Ai [50]	LBP+Adaboost	FERET	3,540	93.30%
Yunchun & Zhan [25]	LBP + ANN	FERET	1,199	92.91%
Yunchun & Zhan [25]	PCA+ANN	FERET	1,199	91.91%
Fazl-Ersi et al [63]	LBP&SIFT+ SVM	Gallagher	200	91.59%
Liu et al [20]	LBP + SVM	LFW	5,660	91.43%
Makinen & Raisamo [3]	LUT + ANN	FERET	900	91.11%
Sungh et al [19]	LBP + SVM	Indian faces	300	89.43%
Eidinger et al [65]	LBP + SVM	Gallagher	1,270	88.40%
Costen et al [10]	PCA + LDA	Japanese Faces	300	79.75%
Makinen & Raisamo [3]	LBP + SVM	WWW	4,720	78.25%

2.6. Yaş Tahmini

Tablo 2.2. Ortak yaş tahmin yöntemleri


Araştırma	Yöntem	Veri tabanı	Görüntü Sayısı	Doğruluk
Azarmehr et al [40]	LBP + SVM	Gallagher	5,080	98.80%
Guo et al [41]	BIF + SVM	YGA	1,600	
Guo et al [54]	PCA + BIF	MORPH-II	55,000	95.56%
Yan et al [38]	PCA + RPK	FG-NET	1,002	95.05%
Gup et al [36]	LARR + SVM	FG-NET	500	94.93%
Lanitis et al [34]	PCA + ANN	WWW	500	94.42%
Yan et al [40]	SFP + GMM	YGA	1,600	92.18%
Yang and Ai [50]	LBP + Adaboost	PIE	969	92.12%
Guo et al [53]	LBP + SVM	YGA	8,000	90.53%
Guo et al [53]	HOG + SVM	YGA	8,000	88.65%
Shan [45]	LBP + SVM	Gallagher	3,500	87.70%
Eidinger et al [65]	LBP + SVM	Gallagher	1,270	80.70%
Kanno et al	APM + ANN	FG-NET	110	80.00%
Iga et al [48]	GWT + SVM	HOIP	300	67.40%
Fazl-Ersi et al [63]	LBP&SIFT + SVM	Gallagher	200	63.01%
Mahalingam and Ricanek [60]	HOG + SVM	CASTA	714	52.17%
Mahalingam and Ricanek [60]	LBP + SVM	CASTA	714	33.15%

Tablolardan, sistemin performansını etkileyen birkaç önemli faktör olduğunu bildirebilir. Bu faktörler:

- Eğitim setinde kullanılan görüntü sayısının artırılması, yüksek doğrulukların elde edilmesine yardımcı olabilir. Bununla birlikte, bunun dezavantajı uzun işlem süresidir.
- Sağlam yöntemler (LBP + SVM gibi) kullanmak ve doğru şekilde kullanmak performansı artırmaya yardımcı olabilir.
- Her uzmanlık alanı için uygun bir veritabanı seçmek (örn. Cinsiyet tahmini için FERET veritabanı ve yaş tahmini için FG-NET veritabanı) zaman kazanmanıza ve iyi sonuçlar almanıza yardımcı olabilir.

BÖLÜM 3. METODOLOJİ

Bu bölümde, bu tezin özü ve yöntemi açıklanmıştır. Öncelikle önerilen sistemin tekniklerin ve ön işleme aşamalarının genel bir açıklaması gözden geçirilmiştir (Şekil 3.1.). İkinci olarak Transfer öğrenme için InceptionV3 ve MobileNetV2 modelleri sunulmuştur. Üçüncü olarak, SSR-NET modeli hakkında ayrıntılar verilmiştir. Bu tezde kullanılan algoritmaların değerlendirildiği ve uygulandığı veritabanlarına kısa bir bakış sağlanarak üçüncü bölümü bitirilmiştir.



Şekil 3.1. Cinsiyet ve Yaş Tahmin Sistemi Genel Metodolojisi

3.1. Ön İşleme

Cinsiyet ve yaş tahmini sorunlarını çözmek, farklı görüntü boyutları ve nitelikleri, her sorun için uygun veritabanını seçmek ve her deneyde yeterli sayıda görüntü kullanmak gibi bazı temel zorlukların üstesinden gelmeyi gerektirir. Bu nedenle, bu problemleri

çözmenin doğru ve sağlam yollarını sağlamak için sistemi işlemeden önce bazı önemli ön işleme teknikleri uygulanmalıdır. Bu bölümde, bu teknikleri özetleyeceğiz ve sağlam, basit ve kullanımı verimli bir cinsiyet ve yaş tahmini yaklaşımları önereceğiz: IMDB ve Wiki veri kümesi için olağandışı verileri aşağıdaki özelliklerden kaldırıyoruz:

- Birinci, yaş 0'ın altında ve 100'ün üzerindedir, Yüz puanı NaN'dir.
- Veri kümelerinde manuel temizleme yapılmıştır ve yüzü algılama için dlib kütüphanesi kullanılmıştır.
- Yüz algılanmayan veya yüz net olmayan görüntüyü kaldırılmıştır.
- Her model gereksinimini takiben veri normalizasyonu yapılmıştır.
- Veri setleri hazırlandıktan sonra modelleme sürecine başlanmıştır.

Sıfırdan derin bir evrimsel ağın nasıl kurulacağı zaten bilinmektedir. İyi performans elde etmek için gereken ince ayar miktarını da anlıyoruz. Bu görev için transfer öğrenme kavramları kullanılmıştır. Önceden eğitilmiş bir model, transfer öğrenimi göreviyle başlamak için gerekli temel bileşendir.

3.2. Transfer Öğrenme Kavramının Gözden Geçirilmesi

Geleneksel makine öğrenimi ve derin öğrenme algoritmaları şimdiye kadar geleneksel olarak tek başlarına çalışacak şekilde tasarlanmıştır. Bu algoritmalar belirli görevleri çözmek için eğitilmiştir. Özellik alanı dağılımı değişimine göre modeller sıfırdan yeniden oluşturulmalıdır. Transfer öğrenme, izole edilmiş öğrenme paradigmasının üstesinden gelme fikridir. İlgili görevleri çözmek için elde ettiği bilgileri kullanmaktır.

3.3. Motivasyon


İnsanların her şeyi sıfırdan öğrenmediklerini, öğrendikleri ve bilgilerini daha önce öğrenilen alanlardan daha yeni alanlara ve görevlere aktardıkları zaten bilinmektedir. Gerçek Yapay Genel İstihbarat çılgınlığı göz önüne alındığında, transfer öğrenimi veri bilimcilerinin ve araştırmacıların AGI yönündeki ilerlememizi daha da

ilerletebileceklerine inanılmaktadır. Aslında, transfer öğrenimi 2010'larda henüz ortaya çıkmış bir kavram değildir. Sinirsel Bilgi İşleme Sistemleri (NIPS) 1995 çalıştayını Öğrenmeyi Öğrenmek: Endüktif Sistemlerde Bilgi Konsolidasyonu ve Transferi, bu alanda araştırma için ilk motivasyonu sağladığına inanılmaktadır. O zamandan beri, Öğrenmeyi Öğrenme, Bilgi Konsolidasyonu ve Endüktif Transfer gibi terimler, transfer öğrenme ile dönüşümlü olarak kullanılmaktadır. Her zaman, farklı araştırmacılar ve akademik metinler farklı bağlamlardan tanımlar yapmışlardır. Deep Learning isimli ünlü kitaplarında, Goodfellow ve arkadaşları, öğrenmeyi genelleme bağlamında aktarmaya değinmektedirler.

Bu nedenle temel motivasyon, özellikle de derin öğrenme bağlamı göz önünde bulundulduğunda, karmaşık sorunları çözen çoğu modelin çok fazla veriye ihtiyaç duyması ve denetlenen modeller için çok miktarda etiketlenmiş veri elde etmenin zaman ve çaba gerektirdiği dikkate alındığında gerçekten zor olmasıdır. Veri noktalarını etiketlemek gerekir. Basit bir örnek, Stanford'da başlayan yıllarca süren sıkı çalışma sayesinde, farklı kategorilere ait milyonlarca görüntüye sahip olan ImageNet veri kümesidir.

3.4. Transfer Öğrenmeyi Anlama

Burada hatırlanması gereken ilk şey, transfer öğreniminin derin öğrenmeye özgü yeni bir kavram olmamasıdır. Geleneksel makine öğrenimi modelleri oluşturma ve eğitimi yaklaşımı ile transfer öğrenme ilkelerini izleyen bir metodoloji kullanma arasında belirgin bir fark vardır.



Şekil 3.2. Geleneksel öğrenimi vs. transfer öğrenimi

Şekil 3.2. Geleneksel öğrenimi ve transfer öğrenimi gösterilmiştir, geleneksel öğrenme izole edilir ve tamamen belirli görevlere, veri kümelerine ve bunların üzerinde ayrı ayrı izole edilmiş modellerin eğitime dayanarak gerçekleşir. Bir modelden diğerine aktarılabilecek hiçbir bilgi saklanmaz. Transfer öğrenimde, daha yeni modelleri eğitmek için daha önce eğitilmiş modellerden bilgi almak gerekir. (Özellikler, ağırlıklar, vb.)

3.5. Formal Tanımlama

Şimdi transfer öğrenme için formal tanıma bakalım ve daha sonra farklı stratejileri anlamak için bu tanımları kullanalım. Pan ve Yang [6], transfer öğrenmeyi anlamak için bir çerçeve sunmuşlar ve bunun için alan, görev ve marjinal olasılıkları kullanmışlardır. Çerçeve aşağıdaki gibi tanımlanmaktadır:

A domain, D , bir örnek veri noktası olan özellik alanı χ ve marjinal olasılık, $P(X)$ içeren iki elemanlı bir demet olarak tanımlanır. Böylece, etki alanını matematiksel olarak $D = \{\chi, P(X)\}$ şeklinde temsil edebiliriz. $T = \{Y, P(Y|X)\}$.

Etki alanı ve görev terimleri arasındaki farka biraz daha açıklık getirmek için, aşağıdaki şekil bunları bazı örneklerle açıklamaya çalışmaktadır.

3.6. Önemli Çıkarımlar

Transfer öğrenme, şimdiye kadar gördüğümüz gibi, hedef görevdeki kaynak öğrenciden mevcut bilgileri kullanma yeteneğine sahiptir. Transfer öğrenme sırasında aşağıdaki üç önemli soru cevaplanmalıdır:

Ne aktarılmalı: Bu, tüm süreçteki ilk ve en önemli adımdır. Hedef görevin performansını artırmak için bilginin hangi kısmının kaynaktan hedefe aktarılabilirliği konusunda cevaplar bulmaya çalışıyoruz. Bu soruyu cevaplamaya çalışırken, bilginin hangi kısmının kaynağa özgü olduğunu ve kaynak ile hedef arasında neyin ortak olduğunu belirlemeye çalışıyoruz.

Ne zaman aktarılmalı: Bilgi uğruna aktarımın, her şeyi (negatif aktarım olarak da bilinir) iyileştirmekten daha da kötüleştirebileceği senaryolar olabilir. Hedef görev performansını / sonuçlarını iyileştirmek ve bunları düşürmek için transfer öğrenimini kullanmayı hedeflemeliyiz. Ne zaman transfer yapılacağına ve ne zaman aktarılmayacağına dikkat etmeliyiz.

Nasıl transfer edilmeli: Ne ve ne zaman cevaplandıktan sonra, bilgiyi gerçekten alanlar görevler arasında aktarmanın yollarını belirlemeye devam edebiliriz. Bu, bu makalenin sonraki bölümlerinde ele alacağımız mevcut algoritmalarda ve farklı tekniklerde yapılan değişiklikleri içerir. Ayrıca, nasıl transfer edileceğinin daha iyi anlaşılması için özel vaka çalışmaları da sıralanmıştır.

3.7. Öğrenme Stratejilerini Aktarma

Alan adı, eldeki görev ve verilerin kullanılabilirliğine bağlı olarak uygulanabilecek farklı transfer öğrenme stratejileri ve teknikleri vardır:

- **Tümevarım transfer öğrenme:** Bu senaryoda, kaynak ve hedef etki alanları aynıdır, ancak kaynak ve hedef görevler birbirinden farklıdır. Algoritmalar, hedef görevin iyileştirilmesine yardımcı olmak için kaynak etki alanının

endüktif sapmalarını kullanmaya çalışır. Kaynak etki alanının etiketli veri içerip içermediğine bağlı olarak, bu, sırasıyla çok görevli öğrenme ve kendi kendine öğrenilen öğrenme gibi iki alt kategoriye ayrılabilir.

- Transdüktif transfer öğrenme: Bu öğrenmede, hedef etki alanındaki denetimsiz görevlere odaklanarak endüktif transferin kendisine benzer. Kaynak ve hedef etki alanları benzer, ancak görevler farklıdır. Bu senaryoda, etiketli veriler her iki etki alanında kullanılamaz.
- Transdüktif aktarım öğrenme: Bu senaryoda, kaynak ve hedef görevler arasında benzerlikler vardır, ancak karşılık gelen alanlar farklıdır. Bu öğrenmede, kaynak etki alanında çok fazla etiketli veri bulunurken, hedef etki alanında hiçbir veri yoktur. Bu öğrenme, özellik boşluklarının farklı olduğu ya da marjinal olasılıkların ayarlarına bakarak alt kategorilere ayrılabilir.

Yukarıdaki tekniklerin her biri için farklı ayarları ve senaryoları aşağıdaki tabloda özetleyebiliriz.

Tablo 3.1. Transfer Öğrenme Stratejilerinin Türleri ve Ayarları

Öğrenme stratejisi	Alanlar	Kaynak ve hedef alanları	Kaynak alan etiketleri	alan etiketleri	Kaynak ve hedef görevler	görevler
Endüktif transfer öğrenimi	Multi-task learning	aynısı	Mevcut	Mevcut	Farklı ama ilişkili	dönüş sınıflandırma
	Kendi kendine öğrenme	aynısı	Mevcut değil	Mevcut	Farklı ama ilişkili	dönüş sınıflandırma
Denetimsiz transfer öğrenimi		Farklı ama ilişkili	Mevcut değil	Mevcut değil	Farklı ama ilişkili	kabuklanma Boyut Azaltma
	Alan uyarlaması, örnek seçimi Sapma ve Değişken kaydırma	Farklı ama ilişkili	Mevcut	Mevcut değil	aynısı	dönüş sınıflandırma

Önceki bölümde tartışılan üç transfer kategorisi, transfer öğreniminin uygulanabileceği ve ayrıntılı olarak incelenebileceği farklı ayarları ana hatlarıyla

belirtir. Bu kategoriler arasında nelerin aktarılacağı sorusunu cevaplamak için aşağıdaki yaklaşımlardan bazıları uygulanabilir:

Örnek aktarımı: Bilginin kaynak etki alanından hedef göreve yeniden kullanılması genellikle ideal bir senaryodur. Çoğu durumda, kaynak etki alanı verileri doğrudan yeniden kullanılamaz. Bunun yerine, kaynak etki alanından sonuçları iyileştirmek için hedef verilerle birlikte yeniden kullanılabilen belirli örnekler vardır. Tümevarım aktarımı durumunda, Dai ve ortak yazarları tarafından AdaBoost gibi değişiklikler, hedef görevdeki iyileştirmeler için kaynak etki alanındaki eğitim örneklerinin kullanılmasına yardımcı olur.

Özellik gösterimi aktarımı: Bu yaklaşım, kaynaktan hedefleri hedeflemek için kullanılacak iyi özellik gösterimlerini belirleyerek etki alanı sapmasını en aza indirmeyi ve hata oranlarını azaltmayı amaçlamaktadır. Etiketli verilerin mevcudiyetine bağlı olarak, özellik temsili tabanlı aktarımlar için denetimli veya denetimsiz yöntemler uygulanabilir.

Parametre aktarımı: Bu yaklaşım, ilgili görevler için modellerin bazı parametreleri veya hiperparametrelerin önceki dağılımını paylaştığı varsayımı üzerinde çalışır. Hem kaynak hem de hedef görevlerin aynı anda öğrenildiği çok görevli öğrenmenin aksine, transfer öğrenimi için, genel performansı iyileştirmek için hedef etki alanının kaybına ek ağırlık uygulayabiliriz.

İlişkisel bilgi aktarımı: Önceki üç yaklaşımdan farklı olarak, ilişkisel bilgi aktarımı bağımsız ve aynı şekilde dağılmamış veriler gibi IID dışı verileri işlemeye çalışır. Diğer bir deyişle, her veri noktasının diğer veri noktalarıyla ilişkisi olduğu veriler; örneğin, sosyal ağ verileri ilişkisel-bilgi aktarım tekniklerini kullanır.

Aşağıdaki tabloda farklı transfer öğrenme stratejileri ile neyin transfer edileceği arasındaki ilişki özetlenmiştir.

Tablo 3.2. Öğrenme Stratejilerini ve Aktarılabılır Bileşen Türlerini aktarma

	Endüktif Transfer Öğrenimi	Transdüktif Transfer Öğrenimi	Denetimsiz Transfer Öğrenimi
Örnek -transfer	√	√	
Özellik-temsil-transfer	√	√	√
Parametre transferi	√		
İlişkisel-bilgi-transfer	√		

Şimdi bu anlayışı kullanacağız ve transfer öğreniminin derin öğrenme bağlamında nasıl uygulandığını göreceğiz.

Özellik Ayıklayıcıları Olarak Hazır Eğitilmiş Modeller: Derin öğrenme sistemleri ve modelleri, farklı katmanlardaki farklı özellikleri öğrenen katmanlı mimarilerdir (katmanlı özelliklerin hiyerarşik gösterimleri). Bu katmanlar daha sonra son çıktıyı elde etmek için son bir katmana (genellikle denetimli öğrenme durumunda tamamen bağlı bir katman) bağlanır. Bu katmanlı mimari, son katmanı diğer görevler için sabit bir özellik çıkarıcısı olmadan önceden eğitilmiş bir ağı (Inception gibi) kullanmamızı sağlar.

3.8. Önceden Eğitilmiş Modeller

Transfer öğrenimi için temel gereksinimlerden biri, kaynak görevlerde iyi performans gösteren modellerin varlığıdır. Neyse ki, derin öğrenme dünyası paylaşıma inanır. En gelişmiş derin öğrenme mimarilerinin birçoğu kendi ekipleri tarafından açıkça paylaşılmıştır. Bunlar, derin öğrenme uygulamaları için en popüler iki alan olan bilgisayar görme ve NLP gibi farklı alanlara yayılmıştır. Önceden eğitilmiş modeller genellikle istikrarlı bir duruma getirilirken modelin elde ettiği milyonlarca parametre ağırlık şeklinde paylaşılır. Herkesin farklı yöntemlerle kullanması için önceden eğitilmiş modeller mevcuttur. Ünlü derin öğrenme Python kütüphanesi, keras, bazı popüler modelleri indirmek için bir arayüz sağlar.

3.9. Yaş ve Cinsiyet Sınıflandırması İçin CNN


Makine öğrenimi açısından, görüntülere dayalı bir ikili sınıflandırma problemidir. Başlamadan önce, kullandığımız modellerin Francois Chollet tarafından oluşturulan

bilgi kütüphanesinden geldiğini, aktarma öğreniminin `` Python ile Derin Öğrenme '' kitabında etkili olduğu gerçek dünya sorunundan bahsediyorduk. Bunu bu bölümde transfer öğreniminin gerçek gücünü tasvir etmek için bir ilham kaynağı olarak gördük ve tüm sonuçlar her bir modeli kendi GPU tabanlı bulut kurulumumuzda oluşturmaya ve çalıştırmaya dayanıyor.

3.10. Veri setleri

3.10.1. IMDB-WIKI veritabanı

IMBD-WIKI Veritabanı eğitim için cinsiyet ve yaş etiketleri, IMDb'den 20.284 ünlü ve Wikipedia'dan 62.328, dolayısıyla toplamda 460.723 olan halka açık büyük veri veri kümesidir [8].



Şekil 3.3. IMDB ve WIKI veritabanından bir örnek

3.10.2. FG-NET veritabanı

FG-NET: Yüz ve Hareket Tanıma Araştırma Ağı (FG-NET), cinsiyet ve yaş etiketleri ile en büyük yüz görüntüleri veri kümesidir. Cinsiyetlerin eşit dağılımı, ancak ırkların eşit olmayan dağılımı ile 23.708 yüz içerir. Beş etiketli ırk Beyaz, Siyah, Asya, Hint ve Diğerleri'dir (Hispanik, Latin ve Orta Doğu gibi).



Şekil 3.4. FG-NET veritabından bir örnek

3.10.3. Adience veritabanı

Yaş ve cinsiyet sınıflandırması için Adience ölçütü vardır. Toplanan 26.580 kısıtsız yüz görüntüsünü içerir. Görüntüler, çeşitli aydınlatma koşulları altında farklı kafa pozları ve yaşları olan insanları içerir. Deneylerde kullanılan kıvrımlar rastgele seçildi, burada her kıvrım ortalama 970 görüntü içeriyordu. Yüz tanıma;



Şekil 3.5. Adience veritabından bir örnek


3.10.4. UTKFace veritabanı

UTKFace, yaş aralığı 0 ila 116 yıl arasında değişen büyük ölçekli bir yüz veri kümesidir. Bu veri kümesi, yaş, cinsiyet ve etnik köken ek açıklamalarına sahip 23.709 yüz görüntüsü içerir.



Şekil 3.6. UTKFace veritabından bir örnek

3.10.5. Veri setlerimizin yaş dağılımı




Şekil 3.7. Kullanılan veritabanlarının yaş dağılımı

Şekil 3.7. veri setlerimizin dağılımı göstermiştir, görüldüğü gibi en çok kullanan yaş grubu 30-49'dur.

3.11. Sıfırdan Basit CNN Modeli

Şekil 3.8.'de üç kıvrımlı katman içeren temel bir CNN modeli oluşturulmuş, görüntülerden özelliklerin otomatik olarak çıkarılması için maksimum havuzlama ile birlikte ve çıkış kıvrım özellik haritalarının altörneklenmesiyle başlayacağız.




Şekil 3.8Wikipedia'dan tipik bir CNN modeli

Artık Keras'tan yararlanarak CNN model mimarisi inşa edilebilir.

3.12. InceptionV3 Mimarisinin Gözden Geçirilmesi

Başlangıçtaki derin evrimsel mimarinin 4 versiyonu vardır, ilki GoogLeNet Inception-v1'dir. Bu model burada Inception-v1 olarak adlandırılan (Szegedy ve ark. 2015'a) 'da GoogLeNet olarak tanıtılmıştır. Daha sonra Inception mimarisi, önce parti normalizasyonu (Inception-v2) eklenerek farklı şekillerde rafine edilmiştir. Daha sonra üçüncü tekrarlamada bu raporda Inception-v3 olarak anılacaktır.

Inceptionv3, görüntü sınıflandırması konusunda önceden eğitilmiş derin bir sinir ağıdır, yaklaşık 25 milyon parametreye sahiptir ve tek bir görüntüyü sınıflandırmak için 5 milyar çarpma kayan nokta işlemi kullanır. 1000 sınıflı genel nesneleri tanımak için son teknoloji doğruluğu sağlar ve ilk kısımdaki giriş görüntülerinden genel özellikleri çıkarır ve ikinci kısımdaki bu özelliklere göre sınıflandırır.



Şekil 3.9. Inception V3'ün şematik diyagramı

Bu model için, sınıflandırıcı olmadan 140 x 140 piksel giriş boyutunu kullanılmıştır. Görüntüleri sınıflandırmayı düşündüğümüzde, genellikle en iyi uyum için modelimizi sıfırdan oluşturmayı tercih ederiz. Bu bir seçenektir, ancak özel bir derin öğrenme modeli oluşturmak kapsamlı hesaplama kaynakları ve birçok eğitim verisi gerektirir. Yani orijinal veri kümesini sınıflandırmak için yeni bir model oluşturulduğunda, özellik çıkarma bölümünü yeniden kullanır ve yeniden -Sınıflandırma kısmı veri seti ile eğitilir. Modeli daha az hesaplama kaynağı ve eğitim süresi ile eğitebileceğimiz göz önüne alındığında, özellik çıkarma bölümünü eğitmek zorunda değiliz.

3.13. MobilNetV2 Modelinin Gözden Geçirilmesi


MobileNets'in arkasındaki büyük fikir, hafif derin sinir ağı oluşturmak için derinlemesine ayrılabilir kıvrımlar [16] kullanması ve Keras'ın uygulamalarından birine dahil edilmesidir. Üst katman hariç bu evrişimli sinir ağı, yukarıda belirtilen boşta alınmış tabakanın yerini alan özel olarak tasarlanmış bir sınıflandırma bloğu ile model için temel görevi görür.

MobileNets esas olarak başlangıçta [26] 'da tanımlanan derinlemesine ayrılabilir kıvrımlardan oluşur ve daha sonra ilk birkaç katmandaki hesaplamayı azaltmak için Başlangıç modellerinde [13] kullanılır. Yassılaştırılmış ağlar [16] tamamen çarpanlara ayrılmış kıvrımlardan oluşan bir ağ kurar ve aşırı çarpanlara ayrılmış ağların

potansiyelini gösterir. Bu makaleden bağımsız olarak, Faktörize Ağlar [34] topolojik bağlantıların kullanımının yanı sıra benzer bir faktörlü evrişim sunmaktadır. Daha sonra, Xception ağı [3], Inception V3 ağlarından daha iyi performans göstermesi için akıllı ayrılabilir filtrelerin derinliğinin nasıl büyütüleceğini gösterir. Başka bir küçük ağ, çok küçük bir ağ tasarlamak için darboğaz yaklaşımı kullanan Squeezenet [12] 'dir. Diğer azaltılmış hesaplama ağları arasında yapılandırılmış dönüşüm ağları [28] ve kızartılmış manastırlar [37] yer alır.


3.14. SSR-Net Gözden Geçirilmesi

Önerdiğimiz eğitim modelimiz, bazı değişikliklerle SSR-net üzerine kurulmuştur. Yang ve diğ. [14] yaş ve cinsiyeti tanımak için yumuşak aşamalı regresyon (yumuşak stagewise regresyon ağı) ile yaş tahmini için yeni bir yaklaşım geliştirmişlerdir. Ağ, yaş ve cinsiyeti aşağıdaki prensibe göre tanır: 64x64 piksellik görüntüler ağın girişine beslenir, her seviyenin bir önceki sonucu ve daha sonra sonucu düzeltmeye yaradığı çeşitli sınıflardan çok düzeyli bir sınıflandırma yapılır. Sınıflandırma bir regresyon kullanılarak işlenir. Modelin kendisi çok kompakttır ve sadece 0.32 MB yer alır. Ancak kompakt boyutlarına rağmen, SSR-Net'in performansı, modellerinin boyutları 1500 kat daha büyük olan en modern yöntemlerin özelliklerine yakındır. Bu sinir ağının üç seviyeli ve havuz büyüklüğü 2 olan bir modeli Şekil 3.10.'da gösterilmektedir.



Şekil 3.10. SSR-Net'in şematik diyagramı

Bu modeli eğitmek için IMDB, WIKI ve Morph2 kullanılmıştır [11]. Bu veri kümelerindeki görüntülerin yaklaşık %80'i rastgele seçilmiştir ve ağı eğitmek için kullanılmıştır ve geri kalan %20'si test için kullanılmıştır. Morph2 verilerinde öğrenilen SSR-Net, MobileNet ve DenseNet ağ tanıma hatalarının sayısının dönem sayısına bağımlılığına bir örnek, Şekil 3.11.'de sunulmaktadır.



Şekil 3.11. Dönemlerin sayısına karşılık tanıma hatalarının grafiği.


Böylece SSR-Net veri setlerimiz sıfırdan eğitilmiştir. Eğitim, AWS P3 örneğinde Nvidia Tesla V100 ile 10 kat çapraz doğrulama ve her biri için 50 dönem, model tutarlılığını kontrol etmek ve her model için en iyi metriklerle ağırlık dosyası almak için yapılmıştır, kullanılan giriş boyutu 64 x 64 pikseldir.

3.15. Özet

Bu bölümde, önerilen sisteme uygulanan ön işleme tekniklerini açıklanmıştır. Bu bağlamda kullandığımız üç model hakkında bir inceleme yapılmıştır. Ayrıca, transfer eğilimi kavramı ve bunun endüstride ana akım benimsenmesinde makine öğrenimi ve derin öğrenme başarısı için kesinlikle anahtar faktörlerden biri olacağı açıklanmıştır.

BÖLÜM 4. UYGULAMA VE SONUÇLAR

Kayıp, eğitim ve doğrulama ile hesaplanır ve yorumu modelin bu iki set için ne kadar iyi performans göstermesiyle elde edilir. Doğruluktan farklı olarak, kayıp bir yüzde değildir. Eğitim veya doğrulama setlerinde her örnek için yapılan hataların toplamıdır. Aşağıdaki şemalarda, iki farklı modelin kayıplarını temsil eden iki grafik vardır, sol grafiğin yüksek kaybı ve sağ grafiğin düşük kaybı göstermektedir (Şekil 4.1.).




Şekil 4.1. Öğrenme oranının Kayıp Üzerine Etkisi

4.1. Sonuçlar


Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	(None, 96, 96, 3)	0	
Conv1_pad (ZeroPadding2D)	(None, 97, 97, 3)	0	input_1[0][0]
Conv1 (Conv2D)	(None, 48, 48, 32)	864	Conv1_pad[0][0]
bn_Conv1 (BatchNormalization)	(None, 48, 48, 32)	128	Conv1[0][0]
Conv1_relu (ReLU)	(None, 48, 48, 32)	0	bn_Conv1[0][0]
expanded_conv_depthwise (Depthwise Conv2D)	(None, 48, 48, 32)	288	Conv1_relu[0][0]
expanded_conv_depthwise_BN (BatchNormalization)	(None, 48, 48, 32)	128	expanded_conv_depthwise[0][0]
expanded_conv_depthwise_relu (ReLU)	(None, 48, 48, 32)	0	expanded_conv_depthwise_BN[0][0]
expanded_conv_project (Conv2D)	(None, 48, 48, 16)	512	expanded_conv_depthwise_relu[0][0]
Conv_1_bn (BatchNormalization)	(None, 3, 3, 1280)	5120	Conv_1[0][0]
out_relu (ReLU)	(None, 3, 3, 1280)	0	Conv_1_bn[0][0]
global_average_pooling2d_1 (Global Average Pooling)	(None, 1280)	0	out_relu[0][0]
gender_prediction (Dense)	(None, 2)	2562	global_average_pooling2d_1[0][0]
age_prediction (Dense)	(None, 101)	129381	global_average_pooling2d_1[0][0]
Total params: 2,389,927			
Trainable params: 2,355,815			
Non-trainable params: 34,112			

Şekil 4.2. Kullanılan modellerden birinin sonuçlarına bir örnek


Önceki çıktı bize temel CNN modeli özetimizi göstermektedir (Şekil 4.2.). Daha önce de belirttiğimiz gibi, Keras uygulamasından InceptionV3 ve MobileNetV2'yi sınıflandırıcı çıkışı olmadan kullanılmıştır ve 2 çıkış katmanını olacak şekilde değiştirilmiştir. Bunlardan biri 2 düğümlü cinsiyet tahmini için, diğeri 101 düğümlü yaş tahmini için (0-100 yaşını temsil eder)'dir. Softmax regresyondan hesaplanan çıktısı ile yaş tahmini çok sınıflı sınıflandırma problemi olarak ele alınmıştır.



Şekil 4.3. SSR-Net model 'in Dönem vs Kayıp Grafikler



Şekil 4.4. InceptionV3'in Dönem vs Kayıp Grafikler



Şekil 4.5. MobileNetV2'in Dönem vs Kayıp Grafikler

Bir modelin kayıp düşüşlerinin hızlı bir şekilde alındığı açıkça görülmektedir ve yaklaşık 1 özel MobileNetV2'ye yaklaşıyor, makul doğrulukla çıkarımda oldukça hızlıdır. Bu, aktarım öğrenmesinin ne kadar güçlü, ancak basit olabileceğinin açık bir örneğidir.

4.2. Değerlendirme

Eğitim ve doğrulama performansı oldukça iyidir, ancak görünmeyen verilerdeki performans belirsizdir. Orijinal veri setimiz üç ayrı bölüme ayırmıştık. Burada hatırlanması gereken önemli nokta, test veri kümesinin eğitim veri kümesiyle benzer ön işleme tabi tutulması gerektiğidir. Bunu hesaba katmak için, işleve beslemeden önce test veri kümesi de ölçeklendiririz.

4.3. Eğitim Parametreleri

Transfer öğrenme tekniklerindeki değişikliklerin etkilerini karşılaştırmak için, aksi belirtilmedikçe tüm eğitim parametreleri tutarlıdır. UTKFace ve FGNET veri kümesi kullanılmıştır. ResNet50 mimarisi üzerine inşa edilmiş InsightFace projesinden yaş ve cinsiyet modeli de denenmiştir.

Cinsiyet modelleri ikili çapraz entropi kaybı işlevini kullanır ve yaş modelleri ortalama mutlak hata (MAE) kullanır. Yaş tahmini sonuçları MAE olarak rapor edilmiştir.

Bu nedenle, MAE, tahmin edilen yaş ile konunun gerçek yaşı arasındaki mutlak farklılıkların ortalamasıdır. Cinsiyet için, sonuçlar doğruluk olarak rapor edilmiştir.


Tablo 4.1. Ort MAE çözümü

Model	Veritabanı	Avg MAE
InceptionV3	FGNET	7.50
	UTKFace	7.36
MobilenetV2	FGNET	9.09
	UTKFace	7.96
Insightface	FGNET	10.55
	UTKFace	7.57
SSRNet	FGNET	13.13
	UTKFace	9.58

Az sayıda FG-NET yüz veritabanından dolayı, son çalışmalar bu veritabanındaki ilgili algoritmanın iyileştirme için çok sınırlı alana sahip olduğunu göstermiştir. Bu algoritmanın etkinliğini daha da doğrulamak için, bu bölüm utkface veritabanında daha fazla deney yapmış olacaktır.

Farklı özellik çıkarma yöntemlerinin deneysel sonuçları Tablo 4.1.'de gösterilmektedir. Üç model kullanılarak yaş tahmininin karşılaştırılmasını göstermektedir. Yukarıdaki deneysel sonuçlardan göre, en iyi MAE yaş tahminimiz UTKFace veri kümesi ve InceptionV3 kullanılarak elde edilmiştir. Tablo 4.1.'den görülebileceği gibi UTKFace veri kümesi ve inceptionv3 modelinin kombinasyonu 7.36 MAE'ye ulaşmaktadır.

4.3.1. FGNET dataset




Şekil 4.6. FG NET veri kümesi için ortalama MAE değerleri.

Şekil 4.6.'de FGNET veri kümesi için kullandığımız modellerin Ortalama Mutlak Hata gösterilmiştir.


Birinci model: inceptionV3 modeli için Ortalama Mutlak Hata 7.50 verilmiştir, MobilenetV2 için 9.09 hata verilmiştir sonra ssr-net için 13.13 ortalama hata sonuç verilmiştir.

4.3.2. UtkFace dataset



Şekil 4.7. UTKFace veri kümesi için ortalama MAE değerleri.

Inceptionv3 için %90,18, mobileNetv2 için %80,74, Insightface %88,71 ve %85,08 gibi inanılmaz bir doğruluk oranı elde edilmiştir (Şekil 4.7.)



Şekil 4.8. UTKFace veri kümesi için ortalama MAE değerleri.

Burda, Şekil 4.8. UTKFace veri kümesi için ortalama MAE değerleri göstermiştir, ve sonuç olarak ssrnet kullandığı zaman yaş tahmini'in ortalama değeri 9.56 sonuç verilmiştir, ve mobilenetV2 7.97, insightface 7.57 ve inceptionv3 7.36 sonuçlanmıştır.

4.4. Transfer Öğrenmesinin Avantajları

Önceki bölümlerde transfer öğreniminin bazı avantajlarını zaten ele alınmıştı. Genellikle transfer öğrenimi, çok çeşitli görevleri yerine getirebilecek daha sağlam modeller geliştirmemizi sağlar.

- Karmaşık gerçek dünya sorunlarını çeşitli kısıtlamalarla çözmeye yardımcı olur
- Etiketli veri mevcudiyeti çok az veya neredeyse hiç yok gibi sorunlarda iyi performans gösterir.
- Alanlara ve görevlere dayalı olarak bir modelden diğerine bilgi aktarma kolaylığı sağlar.
- Gelecekte bir gün Yapay Genel İstihbarat'a ulaşmak için bir yol sağlar!

4.5. Transfer Öğrenme Zorlukları

Transfer öğrenimi muazzam bir potansiyele sahiptir ve mevcut öğrenme algoritmaları için yaygın olarak gerekli bir gelişmedir. Ancak, transfer öğrenmeyle ilgili daha fazla araştırma ve araştırmaya ihtiyaç duyan bazı ilgili konular vardır. Negatif transfer ve transfer sınırlarının neyin, ne zaman ve nasıl transfer edileceği ile ilgili soruları cevaplamanın zorluğunun yanı sıra, büyük zorluklar da vardır.

Negatif Aktarım: Şimdiye kadar tartıştığımız vakalar, kaynak görevden bilgi aktarımına dayalı olarak hedef görevlerdeki gelişmeler hakkındadır. Transfer öğreniminin performansta bir düşüşe yol açabileceği durumlar vardır. Negatif aktarım, bilginin kaynaktan hedefe aktarılmasının herhangi bir gelişmeye yol açmadığı, bunun yerine hedef görevin genel performansında bir düşüşe neden olduğu senaryoları ifade eder. Kaynak görevin hedef görevle yeterince ilişkili olmadığı veya aktarma yönteminin kaynak ve hedef görevler arasındaki ilişkiyi çok iyi kaldıramadığı durumlar gibi olumsuz aktarımın çeşitli nedenleri olabilir. Negatif aktarımdan kaçınmak çok önemlidir ve dikkatli bir araştırma gerektirir. Rosenstien ve ark. çalışmalarında kaba kuvvet transferinin kaynak ve hedef çok farklı olmadığında hedef görevlerdeki performansı nasıl düşürdüğünü ampirik olarak sunarlar. Bakker ve ark. tarafından yapılan Bayesci yaklaşımların yanı sıra, ilişkiyi tanımlamak için kümelenmeye dayalı çözümleri araştıran diğer teknikler de olumsuz aktarımlardan kaçınmak için kullanılır.

Transfer Sınırları: Transfer öğreniminde transferin nicelendirilmesi de transferin kalitesini ve yaşayabilirliğini etkileyen çok önemli bir faktördür. Aktarım miktarını ölçmek için Hassan Mahmud ve ark., aktarım öğrenmesini analiz etmek ve görevler arasındaki ilişkiyi ölçmek için belirli teorik sınırları kanıtlamak için Kolmogorov karmaşıklığını kullanmışlardır. Eaton ark., bilgi transferini ölçmek için yeni bir grafik tabanlı yaklaşım sunmuşlardır.


4.6. Sonuç ve Gelecek Çalışmalar

Bu tez transfer öğrenme kavramları, stratejileri, derin transfer öğrenmeye odaklanma, zorluklar ve avantajlarla ilgili kapsamlı bilgiler içermektedir. Ayrıca, bu tekniklerin nasıl uygulanacağı konusunda iyi bir fikir vermek için uygulamalı iki gerçek dünya vaka çalışması ele alınmıştır.

Transfer öğrenme, sektörde yaygın olarak makine öğrenmesi ve derin öğrenme başarısı için kesinlikle anahtar faktörlerden biri olacaktır. Bu konsept ve metodolojiden faydalanan daha önceden eğitilmiş modeller ve yenilikçi vaka çalışmaları göreceğimizden kesinlikle eminiz. Gelecekteki çalışmalarımızdan bazıları için bu 4 nokta üzerinde çalışılması düşünülmektedir:

- NLP için Öğrenimi Aktarma
- Ses Verilerinde Öğrenmeyi Aktarma
- Üretken Derin Öğrenme için Öğrenimi Aktarma
- Görüntü Altyazısı gibi daha karmaşık Bilgisayar Görme sorunları

4.7. Çıkarım süresi - Performans Puanı



Şekil 4.9. Docker ve nvidia docker AGX platformu kullanarak eşzamanlılık

Şekil 4.9. Çıkarım Süresi göstermiştir, yaklaşımımız arasındaki çıkarım süresini karşılaştırmıştır, kullanıldığı dört modeller (inceptionv3, mobilenetv2, ssrnet ve insightface) arasında karar vermek zordur çünkü her model arayüz zamanı ile bağlıdır, mesela 16'da zamanı inceptionv3 modeli en hızlı modeldir, 10'da ms en hızlı mobilenetv2 modelidir.

4.8. Web'den gerçek zamanlı yaş ve cinsiyet tahmini

Bu proje uygulanırken, insan cinsiyetini ve yaşını imgeyle tahmin etmek için farklı makale ve modelleri analiz edilmiştir. Ayrıca henüz hesaplanamayacak kadar büyük ve yavaş olan yüksek doğrulukta bir çok iyi model olduğu keşfedilmiştir. Öte yandan, gerçek zamanlı video işleme için kullanılabilecek daha düşük hassasiyete sahip bazı küçük modeller vardır. Bu çalışmada bu modeller yaş ve cinsiyet tahminine uygulanmıştır; modelleri denemek için stream.py kullanılmıştır. SORT tracker, tahmin sonucu için yaş ve cinsiyet tahmini yumuşatma eklemek için entegre edilmiştir.


usage: video.py [-h] [-s SRC]

optional arguments:

-h, --help show this help message and exit

-s SRC, --src SRC Video stream source, default will be webcam (0)

4.9. Sonular



Şekil 4.10. Gerek zamanlı yaşı ve cinsiyet tahmini

Şekil 4.10. gerek zamanlı makine ğrenme sistemini bir araya getiren sistemimin işlevselliğini göstermektedir. bilgisayarın web kamerası tarafından görülen tüm yüzlerin yaşını ve cinsiyetini tahmin edilmiştir.

Günümüzde kameralar daha ucuz hale gelmiştir ve tam anlamıyla her yere yerleştirilmektedir ama asla bu kameraları izleyecek kadar insan gücüne sahip olunamaz.

RaspberryPI veya diğerküçük platformlarda çalışabilen modeller gibi, video akışının içeriğini gerek zamanlı olarak tahmin edebilecek ve açıklayabilecek küçük ve doğru modellere yönelik bir talep vardır. Ancak bugün araştırmalar çoğunlukla modellerin uygulanabilirliğine değil, doğruluk üzerine yoğunlaşmaktadır.

Elbette, bir videonun içeriğini analiz etmenin hala karmaşık bir görev olduğu iddia edilebilir ve karmaşık görevler zaten tonlarca hesaplama gerektirir. Ancak yüksek verimlilik elde etmenin en az birkaç yolu vardır.

SSR-Net yazarları tarafından önerilen yumuşak staj regresyonu [2]. Aslında NN eğitiminde yeni bir yaklaşımdır. Temel fikirlerini yeniden formüle edersek, derin öğrenmenin sadece regresyon için değil, aynı zamanda sınıflandırma, özellik çıkarma, vb. diğer tüm alanlarına da dağıtılabileceğine inanıyoruz.

Okan Kopuklu, Maryam Babaei, Stefan Hormann, Gerhard Rigoll tarafından önerilen, katman yeniden kullanımı olan evrişimli sinir ağları tarafından önerilen katmanların yeniden kullanımı Aynı filtreleri birden çok kez tekrarlayabiliyorsak neden her birinin kendi parametreleri kullanılmaktadır.

BÖLÜM 5. SONUÇ VE GELECEK ÇALIŞMALAR

Bu bölümde, önceki bölümlerde sunulan en önemli noktalar sonuçlandırıp özetlenmiştir ve gelecekteki çalışmalar ve yaş ve cinsiyet sınıflandırma sistemlerinin performansını artırmak ve yeteneklerini arttırmak için olası stratejiler belirlenmiştir.

5.1. Sonuç

Bu tezde iki görüntü işleme alanı problemini, cinsiyet tahminini ve yaş tahminini araştırdık ve bu problemler üzerine kapsamlı çalışma yaptık. Bununla birlikte, bu problemleri çözmek kolay değildir çünkü tahmin yöntemleri verilerin analizinde ve bu verilerin genelleştirilmesinde bazı zorluklardan muztariptir, bu nedenle bunu herkese uygulamak kolay bir iş değildir. Bu teze, yüz görüntülerinden cinsiyet ve yaş tahmini ile ilgili zorlukları tanıtarak başladık ve bu alanı incelememizi teşvik eden motivasyonları tartıştık. Ayrıca, bu görevlerle ilgili temel sorunları Bölüm 1'de tarif ettik. Sonra, Bölüm 2'de cinsiyet ve yaş tahmini alanında çeşitli araştırmalara, potansiyel uygulamalara ve sağlam yaklaşımlara genel bir bakış sunuldu.

Bölüm 3'te bu tezin özünü ve yöntemini açıklıyoruz; önce yüz özelliklerinin çıkarılması için kullanılan temel tekniklerin genel bir açıklamasını gözden geçiriyoruz. Daha sonra çalışmada kullanılan sınıflandırma algoritmaları hakkında ayrıntılar verilmiştir. Veritabanlarının görüntülerinin çoğunluğu kısıtlanmamış koşullarda alındığı ve yüz pozisyonu ve parlaklığı farklı olduğu için iyi bir veritabanı seçmenin zorluğu ve önemi nedeniyle, algoritmamızın değerlendirildiği ve uygulandığı veritabanlarına kısa bir bakış sağlayarak bu bölümü bitirdik. Genel olarak, uygun yöntemler ve veritabanları ve uygun sayıda görüntü kullanılması, sistemin performansı ve sonuçları üzerinde olumlu etki yapar. Daha sonra, üç deneysel yaklaşım içeren kapsamlı çalışmalar (Modeller) incelenmiştir.

5.2. Gelecek Çalışmalar

Cinsiyet ve yaş tahmin problemlerine sunulan yöntemler uygulanarak elde edilen ümit verici sonuçlar kapsamında, poz değişikliklerine duyarlı olan etnik öngörüyü iyileştirmek için benzer çabalar gösterilebilir. Bu nedenle, cinsiyet veya yaş veritabanları kullanmak yerine, en belirgin etnik bilgileri sunabilecek etnik veritabanları kullanmak ve aynı cinsiyet ve yaş yaklaşımlarını uygulamak olası bir çözüm olacaktır.

Cinsiyet ve yaş tahmini probleminin bir başka önerisi, ses verileri veya NLP (doğal dil işleme) gibi farklı problemler için önceden eğitilmiş diğer modellerin kullanılma olasılığını araştırmaktır.

KAYNAKLAR

- [1] MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications Andrew G. Howard Menglong Zhu Bo Chen Dmitry Kalenichenko.
- [2] SSR-Net: A Compact Soft Stagewise Regression Network for Age Estimation Tsun-Yi Yang, Yi-Hsuan Huang , Yen-Yu Lin¹ , Pi-Cheng Hsiu¹ , Yung-Yu Chuang
- [3] Bekios-Calfa, J., Buenaposada, J. M., & Baumela, L. (2011). Revisiting linear discriminant techniques in gender recognition. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 33(4), 858-864.
- [4] Costen, N. P., Brown, M., & Akamatsu, S. (2004, May). Sparse models for gender classification. In Automatic Face and Gesture Recognition, 2004. Proceedings. Sixth IEEE International Conference on (pp. 201-206). IEEE.
- [5] Ng, C. B., Tay, Y. H., & Goi, B. M. (2012). Vision-based human gender recognition: A survey. arXiv preprint arXiv:1204.1611.
- [6] Sun, Z., Bebis, G., Yuan, X., & Louis, S. J. (2002). Genetic feature subset selection for gender classification: A comparison study. In Applications of Computer Vision, 2002.(WACV 2002). Proceedings. Sixth IEEE Workshop on (pp. 165-170). IEEE.
- [7] Mäkinen, E., & Raisamo, R. (2008). An experimental comparison of gender classification methods. Pattern Recognition Letters, 29(10), 1544-1556.
- [8] Ng, C. B., Tay, Y. H., & Goi, B. M. (2012). Vision-based human gender recognition: A survey. arXiv preprint arXiv:1204.1611.
- [9] Bekios-Calfa, J., Buenaposada, J. M., & Baumela, L. (2011). Revisiting linear discriminant techniques in gender recognition. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 33(4), 858-864.
- [10] Sun, Z., Bebis, G., Yuan, X., & Louis, S. J. (2002). Genetic feature subset selection for gender classification: A comparison study. In Applications of Computer Vision, 2002.(WACV 2002). Proceedings. Sixth IEEE Workshop on (pp. 165-170). IEEE.

- [11] Moghaddam, B., & Yang, M. H. (2002). Learning gender with support faces. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(5), 707-711.
- [12] Jain, A., & Huang, J. (2004, May). Integrating independent components and linear discriminant analysis for gender classification. In *Automatic Face and Gesture Recognition, 2004. Proceedings. Sixth IEEE International Conference on* (pp. 159-163). IEEE.
- [13] Phillips, P. J., Moon, H., Rizvi, S., & Rauss, P. J. (2000). The FERET evaluation methodology for face- recognition algorithms. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(10), 1090- 1104.
- [14] Phillips, P. J., Wechsler, H., Huang, J., & Rauss, P. J. (1998). The FERET database and evaluation procedure for face-recognition algorithms. *Image and vision computing*, 16 (5), 295-306.
- [15] Phillips, P. J. (1996). FERET (face recognition technology) recognition algorithm development and test results. Army Research Laboratory.
- [16] Sun, N., Zheng, W., Sun, C., Zou, C., & Zhao, L. (2006). Gender classification based on boosting local binary pattern. In *Advances in Neural Networks-ISNN 2006* (pp. 194-201). Springer Berlin Heidelberg.
- [17] Ojala, T., Pietikäinen, M., & Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1), 51-59.
- [18] Romanstan, N., Chellappa, R., & Biswas, S. (2009). Computational methods for modeling facial aging: A survey. *Journal of Visual Languages & Computing*, 20(3), 131-144.
- [19] Fang, Y., & Wang, Z. (2008, August). Improving LBP features for gender classification. In *Wavelet Analysis and Pattern Recognition, 2008. ICWAPR'08. International Conference on* (Vol. 1, pp. 373-377). IEEE.
- [20] Scalzo, F., Bebis, G., Nicolescu, M., Loss, L., & Tavakkoli, A. (2008, December). Feature fusion hierarchies for gender classification. In *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on* (pp. 1- 4). IEEE.
- [21] Zafeiriou, S., Tefas, A., & Pitas, I. (2008, August). Gender determination using a support vector machine variant. In *Signal Processing Conference, 2008 16th European* (pp. 1-5). IEEE.

- [22] Messer, K., Matas, J., Kittler, J., Luetttin, J., & Maitre, G. (1999, March). XM2VTSDB: The extended M2VTS database. In Second international conference on audio and video-based biometric person authentication (Vol. 964, pp. 965-966).
- [23] Lu, L., & Shi, P. (2009, April). A novel fusion-based method for expression-invariant gender classification. In Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on (pp. 1065-1068). IEEE.
- [24] Singh, V., Shokeen, V., & Singh, M. B. (2013, May). Comparison of feature extraction algorithms for gender classification from face images. In International Journal of Engineering Research and Technology (Vol. 2, No. 5 (May-2013)). ESRSA Publications.
- [25] Liu, H., Gao, Y., & Wang, C. (2014, October). Gender identification in unconstrained scenarios using Self- Similarity of Gradients features. In Image Processing (ICIP), 2014 IEEE International Conference on (pp. 5911-5915). IEEE.
- [26] Alexandre, L. A. (2010). Gender recognition: A multiscale decision fusion approach. *Pattern Recognition Letters*, 31(11), 1422-1427.
- [27] Lin, G. S., & Zhao, Y. J. (2011, November). A feature-based gender recognition method based on color information. In Robot, Vision and Signal Processing (RVSP), 2011 First International Conference on (pp. 40-43). IEEE.
- [28] Shan, C. (2012). Learning local binary patterns for gender classification on real-world face images. *Pattern Recognition Letters*, 33(4), 431-437.
- [29] Huang, G. B., Ramesh, M., Berg, T., & Learned-Miller, E. (2007). Labeled faces in the wild: A database for studying face recognition in unconstrained environments (Vol. 1, No. 2, p. 3). Technical Report 07-49, University of Massachusetts, Amherst.
- [30] Ullah, I., Hussain, M., Muhammad, G., Aboalsamh, H., Bebis, G., & Mirza, A. M. (2012, April). Gender recognition from face images with local wld descriptor. In Systems, Signals and Image Processing (IWSSIP), 2012 19th International Conference on (pp. 417-420). IEEE.
- [31] Wang, C., Huang, D., Wang, Y., & Zhang, G. (2012, November). Facial image-based gender classification using local circular patterns. In Pattern Recognition (ICPR), 2012 21st International Conference on (pp. 2432-2435). IEEE.
- [32] Li, M., Bao, S., Dong, W., Wang, Y., & Su, Z. (2013, September). Head-shoulder based gender recognition. In Image Processing (ICIP), 2013 20th IEEE International Conference on (pp. 2753-2756). IEEE.

- [33] Dey, E. K., Khan, M., & Ali, M. H. (2013). Computer Vision-Based Gender Detection from Facial Image. *International Journal of Advanced Computer Science*, 3(8).
- [34] Kwon, Y. H., & Lobo, N. D. V. (1994, June). Age classification from facial images. In *Computer Vision and Pattern Recognition, 1994. Proceedings CVPR'94., 1994 IEEE Computer Society Conference on* (pp. 762- 767). IEEE.
- [35] Ramanathan, N., Chellappa, R., & Biswas, S. (2009). Computational methods for modeling facial aging: A survey. *Journal of Visual Languages & Computing*, 20(3), 131-144.
- [36] Hayashi, J., Yasumoto, M., Ito, H., & Koshimizu, H. (2001). Method for estimating and modeling age and gender using facial image processing. In *Virtual Systems and Multimedia, 2001. Proceedings. Seventh International Conference on* (pp. 439-448). IEEE.
- [37] Hayashi, J., Yasumoto, M., Ito, H., Niwa, Y., & Koshimizu, H. (2002, August). Age and gender estimation from facial image processing. In *SICE 2002. Proceedings of the 41st SICE Annual Conference* (Vol. 1, pp. 13-18). IEEE.
- [38] Kass, M., Witkin, A., & Terzopoulos, D. (1988). Snakes: Active contour models. *International journal of computer vision*, 1(4), 321-331.
- [39] Lanitis, A., Draganova, C., & Christodoulou, C. (2004). Comparing different classifiers for automatic age estimation. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 34(1), 621-628.
- [40] Cootes, T. F., Edwards, G. J., & Taylor, C. J. (2001). Active appearance models. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (6), 681-685.
- [41] Guo, G., Fu, Y., Huang, T. S., & Dyer, C. R. (2008). Locally adjusted robust regression for human age estimation.
- [42] Panis, G., Lanitis, A., Tsapatsoulis, N., & Cootes, T. F. (2015). Overview of research on facial ageing using the FG-NET ageing database. *IET Biometrics*.
- [43] Yan, S., Zhou, X., Liu, M., Hasegawa-Johnson, M., & Huang, T. S. (2008, June). Regression from patch- kernel. In *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on* (pp. 1-8). IEEE.
- [44] Fu, Y., & Huang, T. S. (2006, April). Graph embedded analysis for head pose estimation. In *Automatic Face and Gesture Recognition, 2006. FGR 2006. 7th International Conference on* (pp. 6-pp). IEEE.

- [45] Azarmehr, R., Laganieri, R., Lee, W. S., Xu, C., & Laroche, D. (2015). Real-time embedded age and gender classification in unconstrained video. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 57-65).
- [46] Guo, G., Mu, G., Fu, Y., & Huang, T. S. (2009, June). Human age estimation using bio-inspired features. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on* (pp. 112-119). IEEE.
- [47] Serre, T., Wolf, L., Bileschi, S., Riesenhuber, M., & Poggio, T. (2007). Robust object recognition with cortex-like mechanisms. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(3), 411-426.
- [48] Kanno, T., Akiba, M., Teramachi, Y., Nagahashi, H., & Takeshi, A. G. U. I. (2001). Classification of age group based on facial images of young males by using neural networks. *IEICE TRANSACTIONS on Information and Systems*, 84(8), 1094-1101.
- [49] Bauckhage, C., Jahanbekam, A., & Thureau, C. (2010, August). Age recognition in the wild. In *Pattern Recognition (ICPR), 2010 20th International Conference on* (pp. 392-395). IEEE.
- [50] Shan, C. (2010, October). Learning local features for age estimation on real-life faces. In *Proceedings of the 1st ACM international workshop on Multimodal pervasive video analysis* (pp. 23-28). ACM.
- [51] Gallagher, A., & Chen, T. (2009, June). Understanding images of groups of people. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on* (pp. 256-263). IEEE.
- [52] Ylioinas, J., Hadid, A., & Pietikainen, M. (2012, November). Age classification in unconstrained conditions using LBP variants. In *Pattern Recognition (ICPR), 2012 21st International Conference on* (pp. 1257-1260). IEEE.
- [53] Iga, R., Izumi, K., Hayashi, H., Fukano, G., & Ohtani, T. (2003). A gender and age estimation system from face images. *Age*, 25, 34.
- [54] Ye, J., Zhan, Y., & Song, S. (2004, October). Facial expression features extraction based on gabor wavelet transformation. In *Systems, Man and Cybernetics, 2004 IEEE International Conference on* (Vol. 3, pp. 2215- 2219). IEEE.
- [55] Yang and H. Ai. Demographic classification with local binary patterns. In *Int. Conf. on Biometrics*, pages 464–473, 2007.

- [56] Sim, T., Baker, S., & Bsat, M. (2002, May). The CMU pose, illumination, and expression (PIE) database. In *Automatic Face and Gesture Recognition, 2002. Proceedings. Fifth IEEE International Conference on* (pp. 46-51). IEEE.
- [57] Guo, G., Mu, G., Fu, Y., Dyer, C., & Huang, T. (2009, September). A study on automatic age estimation using a large database. In *Computer Vision, 2009 IEEE 12th International Conference on* (pp. 1986-1991). IEEE.
- [58] Guo, G., Dyer, C. R., Fu, Y., & Huang, T. S. (2009, September). Is gender recognition affected by age?. In *Computer Vision Workshops (ICCV Workshops), 2009 IEEE 12th International Conference on* (pp. 2032- 2039). IEEE.
- [59] Guo, G., & Mu, G. (2010, June). Human age estimation: What is the influence across race and gender?. In *Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on* (pp. 71-78). IEEE.
- [60] Ricanek Jr, K., & Tesafaye, T. (2006, April). Morph: A longitudinal image database of normal adult age- progression. In *Automatic Face and Gesture Recognition, 2006. FGR 2006. 7th International Conference on* (pp. 341-345). IEEE.
- [61] Yan, S., Xu, D., Zhang, B., Zhang, H. J., Yang, Q., & Lin, S. (2007). Graph embedding and extensions: a general framework for dimensionality reduction. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(1), 40-51.
- [62] Cai, D., He, X., Han, J., & Zhang, H. J. (2006). Orthogonal laplacianfaces for face recognition. *Image Processing, IEEE Transactions on*, 15(11), 3608-3614.
- [63] Sun, Z., Paulino, A. A., Feng, J., Chai, Z., Tan, T., & Jain, A. K. (2010, April). A study of multibiometric traits of identical twins. In *SPIE Defense, Security, and Sensing* (pp. 76670T-76670T). International Society for Optics and Photonics.
- [64] Shirkey, D. M., & Gupta, S. R. (2013). An Image Mining System for Gender Classification & Age Prediction Based on Facial Features. *International Journal of Science and Modern Engineering (IJISME)*, 1(6), 8-12.
- [65] Mahalingam, G., & Ricanek, K. (2013, December). Investigating the effects of gender and age group based differences in identical twins. In *Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG), 2013 Fourth National Conference on* (pp. 1-4). IEEE.

- [66] Phillips, P. J., Flynn, P. J., Bowyer, K. W., Bruegge, R. W. V., Grother, P. J., Quinn, G. W., & Pruitt, M. (2011, March). Distinguishing identical twins by face recognition. In *Automatic Face & Gesture Recognition and Workshops (FG 2011)*, 2011 IEEE International Conference on (pp. 185-192). IEEE.
- [67] Cai, D., He, X., Zhou, K., Han, J., & Bao, H. (2007, January). Locality Sensitive Discriminant Analysis. In *IJCAI* (pp. 708-713).
- [68] Fazl-Ersi, E., Mousa-Pasandi, M. E., Laganieri, R., & Awad, M. (2014, October). Age and gender recognition using informative features of various types. In *Image Processing (ICIP)*, 2014 IEEE International Conference on (pp. 5891-5895). IEEE.
- [69] Lowe, D. G. (1999). Object recognition from local scale-invariant features. In *Computer vision, 1999. The proceedings of the seventh IEEE international conference on* (Vol. 2, pp. 1150-1157). IEEE.
- [70] Eidinger, E., Enbar, R., & Hassner, T. (2014). Age and gender estimation of unfiltered faces. *Information Forensics and Security, IEEE Transactions on*, 9(12), 2170-2179.
- [71] Wolf, L., Hassner, T., & Taigman, Y. (2008). Descriptor based methods in the wild. In *Workshop on Faces in 'Real-Life' Images: Detection, Alignment, and Recognition*.
- [72] Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q., Motoda, H., ... & Steinberg, D. (2008). Top 10 algorithms in data mining. *Knowledge and Information Systems*, 14(1), 1-37.
- [73] Dalal, N., & Triggs, B. (2005, June). Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on* (Vol. 1, pp. 886- 893). IEEE.
- [74] Rybski, P. E., Huber, D., Morris, D. D., & Hoffman, R. (2010, June). Visual classification of coarse vehicle orientation using histogram of oriented gradients features. In *Intelligent Vehicles Symposium (IV)*, 2010 IEEE (pp. 921-928). IEEE.
- [75] Satpathy, A., Jiang, X., & Eng, H. L. (2010, September). Extended histogram of gradients feature for human detection. In *Image Processing (ICIP)*, 2010 17th IEEE International Conference on (pp. 3473-3476). IEEE.
- [76] Déniz, O., Bueno, G., Salido, J., & De la Torre, F. (2011). Face recognition using histograms of oriented gradients. *Pattern Recognition Letters*, 32(12), 1598-1603.

- [77] Padole, C. N., & Proenca, H. (2012, March). Periocular recognition: Analysis of performance degradation factors. In *Biometrics (ICB), 2012 5th IAPR International Conference on* (pp. 439-445). IEEE.
- [78] Mary, P. F. G., Paul, P. S. K., & Dheeba, J. (2013). Human Identification Using Periocular Biometrics. *International Journal of Science, Engineering and Technology Research (IJSETR)* Volume, 2.
- [79] Ojala, T., Pietikäinen, M., & Mäenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(7), 971-987.
- [80] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- [81] Begg, R. K., Palaniswami, M., & Owen, B. (2005). Support vector machines for automated gait classification. *Biomedical Engineering, IEEE Transactions on*, 52(5), 828-838.
- [82] Sudha, L. R., & Bhavani, R. (2012). Gait based gender identification using statistical pattern classifiers. *International Journal of Computer Applications*, 40(8), 30-35.
- [83] Barkana, B. D., & Zhou, J. (2015). A new pitch-range based feature set for a speaker's age and gender classification. *Applied Acoustics*, 98, 52-61.
- [84] Platt, J. C., Cristianini, N., & Shawe-Taylor, J. (1999, November). Large Margin DAGs for Multiclass Classification. In *nips* (Vol. 12, pp. 547-553).
- [85] Vapnik, V. N., & Vapnik, V. (1998). *Statistical learning theory* (Vol. 1). New York: Wiley.
- [86] Weston, J., & Watkins, C. (1998). Multi-class support vector machines. Technical Report CSD-TR-98-04, Department of Computer Science, Royal Holloway, University of London, May.
- [87] Crammer, K., & Singer, Y. (2002). On the algorithmic implementation of multiclass kernel-based vector machines. *The Journal of Machine Learning Research*, 2, 265-292.
- [88] He, X., Wang, Z., Jin, C., Zheng, Y., & Xue, X. (2012). A simplified multi-class support vector machine with reduced dual optimization. *Pattern Recognition Letters*, 33(1), 71-82.
- [89] Azarmehr, R., Laganieri, R., Lee, W. S., Xu, C., & Laroche, D. (2015). Real-time embedded age and gender classification in unconstrained video. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 57-65).

ÖZGEÇMİŞ

Zineb FATHI, 10.08.1994 de Fas'ta doğdu. İlk, orta ve lise eğitimini Erfoud-Fas'ta bitirdi. 2012 yılında Sidi Mohammed Ben Abdellah Üniversitesi, Bilgisayar Mühendisliği Bölümünden mezun oldu. 2015 yılında başladığı informatik yönetim 2016 yılında bitirdi. 2018 yılında Sakarya Üniversitesi, yüksek lisans Bilgisayar ve Bilişim Mühendisliği Bölümüne girdi.