



**DERİN ÖĞRENME TABANLI
YÜZ AYIRT ETME VE TANIMA**

Emine CENGİL

**Yüksek Lisans Tezi
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Yrd. Doç. Dr. Ahmet ÇINAR**

AĞUSTOS-2017

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TABANLI YÜZ AYIRT ETME VE TANIMA

YÜKSEK LİSANS TEZİ

Emine CENGİL

(151129108)

Tezin Enstitüye Verildiği Tarih : 24.07.2017

Tezin Savunulduğu Tarih : 10.08.2017

Tez Danışmanı : Yrd. Doç. Dr. Ahmet ÇINAR (F.Ü) 

Diğer Jüri Üyeleri : Yrd. Doç. Dr. Ebubekir ERDEM (F.Ü) 

Doç. Dr. Muhammed Fatih TALU (İ.Ü) 

AĞUSTOS-2017

ÖNSÖZ

Yüz ayırt etme ve tanıma konuları uzun yıllardan beri birçok alanın ilgilendiği araştırma konularıdır. Günümüzde, yüz ayırt etme ve tanıma özellikle güvenlik ve pazar araştırması için kullanılmaktadır. 80'li yılların ortalarından itibaren derin öğrenme mimarilerinin ortaya çıkması ile birlikte, birçok alanda olduğu gibi yüz bulma ve tanıma konularında da derin öğrenme kullanılmaya başlamıştır. Bu çalışma, derin öğrenme mimarisi olan evrimsel sinir ağı tabanlı yüz ayırt etme ve tanıma problemleri için iki yöntem önermektedir. Uygulamamızda, yüz bulma için python ortamında caffe kütüphanesinden faydalanılmıştır. Diğer bir uygulama olan yüz tanıma ise dlib ve opencv kütüphanelerinden faydalanılarak yine python dili ile bir yazılım gerçekleştirilmiştir.

Bu çalışmada değerli vaktini bana ayırarak çalışmamın bitirilmesinde her türlü desteğini esirgemeyen danışman hocam Yrd. Doç. Dr. Ahmet ÇINAR' a teşekkürlerimi sunmak istiyorum.

Ayrıca hayatımın her anında ilgi, anlayış ve her türlü desteğini esirgemeyen aileme de teşekkürü borç bilirim.

TEŞEKKÜR

Bu tez çalışması, MF-16.67'nolu FÜBAP (Fırat Üniversitesi Bilimsel Araştırma Projesi) kapsamında yürütülen araştırma projesi ile desteklenmektedir.

Emine CENGİL
ELAZIĞ - 2017

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	II
İÇİNDEKİLER.....	III
ÖZET	V
SUMMARY	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	IX
KISALTMALAR LİSTESİ	X
1. GİRİŞ	1
1.1. Literatür Özeti	1
1.2. Tezin Amacı ve Kapsamı	12
1.3. Tezin Yapısı	12
2. DERİN ÖĞRENME	13
2.1. Otomatik Kodlayıcılar	14
2.2. Kısıtlı Boltzman Makineleri	15
2.3. Evrişimsel Sinir Ağları	16
2.3.1. Motivasyon	16
2.3.2. Mimari	17
2.3.2.1. Evrişim Katmanı	19
2.3.2.2. Aktivasyon Katmanı	20
2.3.2.3. Havuzlama Katmanı	21
2.3.2.4. Tam Bağlantılı Katman	22
3. CNN TABANLI YÜZ AYIRT ETME YAKLAŞIMI	23
3.1. Veri Seti.....	23

3.2.	CNN Mimarisi	26
3.3.	Eğitim	29
3.3.1.	AlexNeti İnce Ayarlama (Finetuning).....	29
3.3.2.	Caffe Derin Öğrenme Kütüphanesi	31
3.4.	Test ve Sonuçlar	32
4.	CNN TABANLI YÜZ TANIMA YAKLAŞIMI	36
4.1.	Önerilen Yöntemin Edinme yolu.....	36
4.1.1.	Yüz Bulma.....	37
4.1.2.	Ön işleme.....	40
4.1.3.	Özellik Çıkartma	42
4.1.4.	Yüz Tanıma	44
4.2.	Test ve Sonuçlar	45
5.	SONUÇLAR	49
	KAYNAKLAR	50
	ÖZGEÇMİŞ	59

ÖZET

Yüz ayırt etme ve tanıma konuları bilgisayar görmesi alanında uzun yıllardır çalışılan aktif araştırma konularıdır. Literatürde, istatistiksel tabanlı, görünüm tabanlı ve şablon eşleme tabanlı gibi yöntemler bulunmaktadır. Var olan bu yöntemler, poz değişikliği, aydınlanma etkisi ve gürültülü görüntülerde istenilen başarıyı çoğu zaman sağlayamamaktadır.

Son yıllarda, donanımsal kısıtların giderilmesi ile birlikte yapay sinir ağlarının katman sayısı artırılarak derinleştirilmiş modeller geliştirilmiştir. Bu yapılar genel olarak “derin öğrenme” olarak bilinmektedir. Makine öğrenme konularının neredeyse hepsinde kullanılarak, var olan durumu iyileştiren derin öğrenme, görüntü işleme problemlerinin çözümü için de kullanılmaktadır.

Sonuç olarak bu tez çalışmasında son zamanların popüler konusu derin öğrenme irdelenmiş, derin öğrenme mimarilerinden olan evrimsel sinir ağları kullanılarak yüz ayırt etme ve tanıma işlemleri gerçekleştirilmiştir.

Anahtar Kelimeler: Derin öğrenme, Görüntü işleme, Yüz bulma, Yüz tanıma, Evrimsel sinir ağları.

SUMMARY

DEEP LEARNING BASED FACE DETECTION AND RECOGNITION

Face detection and recognition are the most popular research topics that have been working in computer vision for many years. In the literature, there are statistical based, appearance based and template matching based methods for face detection and recognition. However, in most case these methods do not provide the desired success in exposure change, lighting effect and noisy images.

In recent years, with the elimination of hardware constraints, the number of layers of artificial neural networks has been increased and deepened models have been developed. These structures are generally known as "deep learning". The machine is also used in almost all of the learning topics in order to solve deep learning on image processing problems that improve the existing situation.

Consequently, in this thesis, deep learning which is recently the most popular subject in machine learning has been examined and face detection and recognition with the help of CNN (Convolutional Neural Network) have been realized.

Key Words: Deep learning, Image processing, Face detection, Face recognition, Convolutional neural network,

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1 Derin öğrenme sinir ağı yapısı	13
Şekil 2.2 Örnek otomatik kodlayıcı ağ yapısı	14
Şekil 2.3 KBM ağ yapısı	15
Şekil 2.4 Sıradan ağ yapısı	17
Şekil 2.5 Evrişimsel sinir ağı yapısı	18
Şekil 2.6 Havuzlama, evrişim ve tam-bağlı katman içeren örnek bir evrişimsel sinir ağı modeli	18
Şekil 2.7 Evrişim katmanında uygulanan evrişim işlemi	19
Şekil 2.8 Evrişim sinir ağı modelinde en çok kullanılan aktivasyon fonksiyonları	20
Şekil 2.9 2x2 filtre ve 2 adım ile max-havuzlama işlemi	21
Şekil 3.1 Yüz bulma işlemi edinme yolu	23
Şekil 3.2 Yüz bulma veri setlerinden alınmış görüntü örnekleri	24
Şekil 3.3 Alexnet, evrişimsel sinir ağı mimarisi	27
Şekil 3.4 Sistemin öğrenme eğrisi	32
Şekil 3.5 FDDB veri setinden alınmış görüntülerde çoklu yüz bulma.....	33
Şekil 3.6 FDDB veri setinden farklı etnik yapıdaki kişilere ait görüntülerde yüz bulma ..	33
Şekil 3.7 FDDB veri setinden alınmış tek bir yüz içeren görüntülerde yüz bulma	34
Şekil 3.8 Google.com'dan alınmış birden fazla yüz içeren görüntülerde yüz bulma	34
Şekil 3.9 MUCT veri setinden alınmış görüntülerde yüz bulma	35
Şekil 4.1 Yüz tanıma yöntemlerinin edinme yolu	37
Şekil 4.2 (a) Google.com'dan alınmış görüntü (b) yatay degrade maskeli yüz imajı (c) yatay ve dikey degradelerin birleşimi ile oluşmuş yüz imajı (d) dikey degrade maskeli yüz imajı	38
Şekil 4.3 Görüntünün odaklı eğimlerinin histogramı	39
Şekil 4.4 HOG kullanarak LFW veri setindeki görüntülerde yüz bulma	40
Şekil 4.5 LFW veri setindeki görüntülerde yüz işaret tahmini	41
Şekil 4.6 Ön işleme sonrası hizalanmış görüntü	41
Şekil 4.7 Ön işleminden geçirilmiş görüntüden 128 ölçüm eldesi	43

Şekil 4.8 Eğitim verisinden çıkartılan yüz özelliklerine ait ölçümler	44
Şekil 4.9 SVM ile Çoklu sınıflarda sınıflandırma işlemi	45
Şekil 4.10 Önerilen yöntemin özeti.....	46
Şekil 4.11 Kullandığımız örnek 3 sınıfa ait eğitim görüntüleri, (a) Obama (b) Trump ve (c) Biden sınıfına ait görüntüler	47
Şekil 4.12 Sorgu yüzlerine ait test sonuçları	48



TABLÖLAR LİSTESİ

Sayfa No

Tablo 1.1 Yüz bulma için literatürde kullanılmış olan yöntemlerin kategorilerine göre sınıflandırılması.....	7
Tablo 1.2 Yüz tanıma için literatürde bulunan yöntemlerin özeti	11
Tablo 3.1 Yüz bulma problemi için sıklıkla kullanılan uluslararası kabul görmüş veri setleri	25
Tablo 3.2 Alexnet, ile ince ayar sonrası kullanılan model.....	30



KISALTMALAR LİSTESİ

LBP	: Linear Binary Pattern (Yerel İkili Desen)
LGP	: Local Gradient Pattern (Yerel Derece Deseni)
MB-LGP	: Multi-Blok Local Gradient Pattern
SVM	: Support Vector Machine
PCA	: Principal Component Analysis
HOG	: Histogram of Oriented Gradient
DNN	: Deep Neural Network
CNN	: Convolutional Neural Network
LDA	: Linear Discriminant Analysis
FPGA	: Field-Programmable Gate Array
ICA	: Individual Component Analysis
K-PCA	: Kernel Principal Component Analysis
DCT	: Discrete Cosine Transform
LRC	: Logistic Regression Classifier (Logistik Regresyon Sınıflandırıcısı)
AAM	: Active Appearance Model
SIFT	: Scale-Invariant Feature Transform
KBM	: Kısıtlı Boltzmann Makineleri
ReLU	: Rectified Linear Unit

1. GİRİŞ

Son yıllarda bilişim teknolojisinin gelişmesiyle birlikte her alanda akıllı sistemlerin kullanımı kaçınılmaz hale gelmiştir. İnsanı diğer canlılardan ayıran ve sahip olunan en değerli şey olan zekâyı, makinelere öğretme fikrinin cazip gelmesiyle başlayan yapay zekâ kavramı bilim çevrelerince ortaya atılan yeni teknikler sayesinde gelişerek ilerlemiştir. Bu tekniklerin son zamanlarda adından çokça bahsedileni derin öğrenme, oldukça yaygın bir şekilde kullanılmaktadır.

Geçmişte insan faktörünün gerektiği birçok problemin çözümünde artık akıllı sistemler kullanılmaktadır. Bu problemlerden birisi yüz bulmadır. Yüz bulma işlemi, yüz tanıma, duygu analizi yapma, yaş tespiti gibi birçok problemi çözmenin ilk adımı olmasının yanı sıra kişi sayısı belirlemek için de kullanılmaktadır. Kişi sayısı belirleme, pazar araştırması ve güvenlik alanlarınca kullanılmaktadır.

Kişiyi tanıma probleminin çözümü için el, iris, retina ve yüz gibi kişinin fiziksel özelliklerinden faydalanan çalışmalar mevcuttur [1]. Bunlardan en tercih edileni sağladığı avantajlardan dolayı kişiyi yüz görüntüsünden tanımadır. Yüz görüntüsünden tanıma, kişinin rahatsız edilmeden tanınmasını sağlayacaktır. Ayrıca işlem yapılırken kişinin durumdan habersiz olması, yöntemin özellikle güvenlik gibi daha geniş alanlarda kullanımını sağlayacaktır. Son yıllarda artan terör suçlarının önlenmesi veya herhangi bir suçtan aranan kişilerin bulunması için sistemin havayolları, devlet daireleri ve toplu taşıma araçları gibi birçok yerde kullanımı toplum güvenliğini sağlamak açısından oldukça faydalı olacaktır.

1.1. Literatür Özeti

Geçmişten günümüze yüz bulma problemi ile ilgili birçok yöntem geliştirilmiştir. Problemi çözmeye yönelik yapılan çalışmaların akademik ve bilim çevrelerince en çok kullanılmış olanları Ten rengi tabanlı yüz bulma(skin color method), hareket tabanlı yüz bulma, Haar sınıflandırma algoritması ve yapay zekâ algoritmaları (Yapay Sinir ağı, Bulanık Mantık, Derin Öğrenme...) ile geliştirilen yöntemlerdir.

W. Chen ve ark.[2], öncelikle yüz tanıma için cilt rengi modelleme araştırmaları incelemesi sunmuşlardır. Özellikle, cilt renk modellemesi, algılama ve bölütlemenin zorluklarını tartışmaya odaklanmış ve daha sonra cilt renk modellemesi ve bölgeye dayalı cilt bölümlemesini sunmuşlardır. Ayrıca, kömür madeninde çalışan personelin ton özelliklerini analiz etmek için yeni bir yaklaşım önermişlerdir. Görsel tonun tepkisine dayalı olarak sınır tespit yöntemini kullanarak madencilerin cilt rengi sınırları belirlenmiştir. Ardından madenler için cilt rengini bölmek için çift renk detektörü kullanarak renk alanı yöntemini belirlemişlerdir. Test sonuçları, yöntemin madencilerin cilt bölgelerini bölümlere ayırma konusunda mükemmel bir yeteneğe sahip olduğunu göstermiştir.

D. Ghimire ve ark. [3], giriş renk görüntüsünün kenar ve cilt tonu bilgisine dayanan aydınlatmaya duyarsız bir yüz algılama yöntemi sunar. Görüntü bölütleme, yüz bileşenlerini arka planda ayırmak için cilt rengi ve kenar bilgileri kullanılarak geliştirme sonrasında geliştirilir. Bağlanan bileşenler daha sonra birincil şekil özelliklerini ve kenar ve ciltli görüntünün ilgili gri tonlamalı görüntüsünde aday yüz bölgesinin standart sapmasını kullanarak analiz eder.

Sanjay ve ark. [4] , farklı renk modellerinin dinamiklerini beş videonun bir veritabanında incelemiştir. Bu videolar 93.000'den fazla elle açıklanmış yüz görüntüleri içermektedir. Ayrıca, Adaboost yüz bulucusunun yanlış kabul edilme durumunu azaltmak için uyarlanabilir bir cilt rengi modeli önermişlerdir. Yüz renk dağılımı modeli, önceki Adaboost yanıtlarını kullanarak düzenli olarak güncellendiğinden, sistemi gerçek dünyadaki çevre değişkenleri için daha etkili bulmuştur.

Q. Lan ve ark.[5] geleneksel Adaboost yüz algılama algoritması, Haar benzeri özellikleri, yüz bölgesi içinde algılama hatası oranı düşük olan eğitim sınıfı sınıflandırıcılarını kullanmıştır. Bir yüzün en önemli özelliklerinden biri olan YCgCr renk alanındaki cilt iyi kümelenmeye sahiptir. Bu çalışmada Adaboost algoritmasının ve cilt renk algılama algoritmasının avantajlarıyla birleştirilen YCgCr cilt rengi modeline dayanan Adaboost yüz algılama algoritması yöntemi önerilmektedir. Deneyler, geleneksel algoritmayla karşılaştırıldığında, önerilen yöntemin algılama doğruluğunda ve hatalarında önemli ölçüde iyileştiğini göstermiştir.

S. Kang ve ark. [6] , cilt rengi bölgenin algılanması yolu ile kayan pencere tipi bir yüz bulucusunun hızını artırmak için bir yöntem önermektedir. Cilt rengi bölgeyi algılama yoluyla yüz algılama yöntemi çeşitli perspektiflerle incelenmiştir: Renkleri cilt rengine

benzer alan nedeniyle karmaşık arka plan resimleri, yüksek sahte pozitif oranlara neden olur. Buna karşın, görünüme dayanan, kayan bir pencere türünü benimseyen yüz algılama yöntemi, yüksek yüz algılama oranlarını içerebilir, ancak görüntü boyutu arttıkça tarama algılama işlemi sırasında muazzam hesaplama maliyetlerine neden olurken işlem süresi de buna göre genişletilir. Bu çalışma, işleme süresi düşürülen cilt renk bölgesini algılayarak ve kullanarak kayan pencerenin alt pencere boyunu ve algılama alanını kontrol etmek için bir yöntem önermektedir. Haar dalgacık ve LBP özellikli bir yüz tanımlayıcı ile Bao veritabanı görüntülerine ek olarak çevrimiçi olarak 274 görüntü toplanmış ve onlarla yapılan testin sonucunda, mevcut kayar pencere kullanımında yüz algılama süresi azalarak% 47'ye düşürülmüştür.

S. Zhou, ve ark. [7], özellik kümesi olarak yeni Multi-Block Yerel Gradient Desenler (MB-LGP) tanıtarak, ağaç yapısı sınıflandırıcılarını Destek vektör Makine ile birleştiren dört katmanlı bir yüz bulucu önermiştir. MB-LGP, Yerel Gradient Desenlerinin (LGP) geliştirilmiş bir versiyonudur, LGP'deki piksel değerini değiştirmek için bir görüntü bloğundaki ortalama piksel değerini kullanır, böylece büyük ölçekli yapının daha iyi gösterilmesini ve seslere karşı daha dayanıklı olmasını sağlar. Makale aynı zamanda, yüz tanımlayıcısının hızını ve doğruluğunu dengelemek için sınıflandırma bölümünde destek vektör makinesi (SVM) ile çok kutuplu karar ağaçlarını da bir araya getirmiştir. Yöntem, yaygın olarak kullanılan CMU + MIT yüz veri tabanı ile test edilmiş ve kabul edilebilir sonuçlar elde etmiştir.

J. Ruan ve ark.[8], yüz özelliklerine ve LSVM'ye dayanan bir yüz tanıma algoritması önermektedir. Cilt renk bölgelerinden kasıtlı olarak numuneleri ve algılama bölgelerini seçerek numunelerin etkinliği ve sınıflandırıcının performansı iyileştirilir. Ayrıca, örnek görüntüler dalgacık dönüşümü ile sıkıştırılır ve örnek öznitelik vektörü çıkarılır ve ayrık kosinüs dönüşümü ile azaltılır, SVM sınıflandırıcısının eğitim zorluğu ve eşleşme süreleri azaltılır ve algılama hızlandırılır. Sonunda yüz aday bölgeleri gözler ve ağız tespit edilerek doğrulanır.

X. Zhang ve ark. [9], Support Vector Machine (SVM) ile birleştirilmiş İki Boyutlu Temel Bileşen Analizi (PCA) temelli etkin bir yüz algılama yöntemi önermektedir. Öncelikle, nispeten daha düşük hesaplama karmaşıklığına sahip bir 2DPCA kaba filtre, yüzün çoğunu filtrelemek için bütün girdi görüntüsüne uygulanır, daha sonra, nihai kararı vermek için SVM sınıflandırıcısını takip eder ve böylece algılama işlemi hızlanır. Deney

sonuçları, yöntemin karmaşık arka plan altında yüzleri etkili bir şekilde algılayabileceğini ve işleme süresinin tek başına SVM'yi kullanmaktan daha kısa olduğunu göstermektedir.

H. M. El-Bakry ve ark. [10], verilen bir görüntüde insan yüzlerini tanımlamak için daha hızlı bir PCA yaklaşımı getirmiştir. Bu tür bir yaklaşım, girdi imgesini çok küçük boyutlu alt imajlara ayırmıştır. Farklı görüntüler için deneysel sonuçlar, önerilen daha hızlı PCA'nın gürültüye ve kısmi tıkanmaya rağmen yüzleri gerçek zamanlı olarak verimli bir şekilde konumlandırıldığını göstermiştir. Önerilen yaklaşım gerçek zamanlı olarak başka bir nesnenin varlığını / yokluğunu tespit etmek için uygulanabilir.

Y. Li ve ark.[11], bir insan-robot etkileşimli sistem için kullanılan insan yüzü algılama, tanımlama ve izleme yöntemleri ve teknikleri sunmaktadır. Standart görüntü işleme algoritması ile birlikte bulanık bir ten rengi ayarlayıcı, insan yüzlerini algılamak ve daha sonra bunları doğrusal olmayan destek vektör makinesi (SVM) ve Öklid uzaklık ölçümü ile tanımlamak için önerilir.

H. C. Yang ve ark. [12], yönlendirilmiş gradyanların histogramlarına (HOG) dayanan, yüz olmayanları adım adım ayırmak için farklı özellikler ve sınıflandırıcı kullanan bir kaskadlı yüz algılama yöntemi önerirler. Aday özellik seti, farklı tane boyutundaki HOG özelliğiyle oluşturulmuştur; Farklı parametrelili zayıf sınıflandırıcı olarak farklı aşamalarda destek vektör makinesi (SVM) kullanılmıştır.

V. Jones ve ark. [13] yüz bulma için haar sınıflandırıcı kullanmışlardır. Dedektör tarafından kullanılan özelliklerin hızlı bir şekilde hesaplanmasını sağlayan "İntegral Görüntü" adlı yeni bir görüntü sunumu sunmuşlardır. Sınıflandırıcıları bir "kademeli" olarak birleştiren, umut verici yüz benzeri bölgeler üzerinde daha fazla hesaplama hareketi yaparken resmin arka plan bölgelerinin hızlı bir şekilde atılmasını sağlayan bir yöntemdir. Geleneksel bir masaüstünde uygulanan yüz algılama saniyede 15 kare sürmektedir.

J. Coster ve ark.[14], OpenCV programlama kütüphanesi ve Viola-Jones algoritması kullanarak kontrolü yapılan bir ortamda bir kişinin dikkatini ölçmenin mümkün olup olmadığını araştırmıştır. Birinin dikkatini çekip çekmediğini ölçmek için bir dikkat tanımı gereklidir. Dikkat çeken ve dikkati çeken konuların fotoğraflarından oluşan bir veri seti, yazılımın dikkatin ölçülmesi için kullanılabileceğini değerlendirmek için kullanılmıştır. Çalışmanın sonuçları, OpenCV'nin birkaç yanlış pozitiflikle hemen hemen mükemmel bir tespit oranına sahip olduğunu gösterdi. Sonuç, OpenCV programlama kütüphanesinin, kontrol edilen bir çevredeki dikkati ölçmek için kullanılabileceği sonucuna varılmıştır.

Bununla birlikte, çalışmanın sınırlı kapsamı nedeniyle, gerçek dünyadaki bir uygulamada kullanılabilmesi için daha fazla araştırma gerekmektedir.

P. Irgens ve ark.[15] FPGA(Field Programmable Gate Arrays) tabanlı Viola-Jones yüz algılama algoritması sunmuşlardır. Uygulama, bir donanım açıklama dili ile tanımlanan ve uygun fiyatlı DE2-115 değerlendirme kartı üzerinde doğrulanmış eksiksiz bir sistem seviyesi donanım tasarımıdır. Birincil hedef, ulaşılabilir performansı düşük uçlu FPGA çip tabanlı bir uygulama ile incelemektir.

X. Zhao ve ark.[16] bağlam kısıtlamalarını basamaklı AdaBoost çerçevesinde yerel doku modeli ile bütünleştiren, yüz işareti tespiti için yeni bir bağlam modelleme yöntemi önermiştir. Sadece yerel doku bilgisinin yanı sıra küresel bağlam bilgisi insanların yüzlerdeki yüz işaretlerini bulması için kullanılır. Bu nedenle, yüz simgeleri ve çevresi arasındaki ortak oluşumu, diğer bir deyişle, bağlam bilgisini, düşük uzaklıklar açısından, birbirine bitişik olmayan dikdörtgen (NAR) Haar benzeri özellik olarak önerir.

Yapay sinir ağları [17,18,19,20] ve bulanık mantık [21,22,23] kullanılarak geliştirilmiş birçok yüz bulma yöntemi literatürde mevcuttur. Fakat son yıllarda bu yöntemlerin yerini derin öğrenme mimarileri almaya başlamıştır.

Shuo Yang ve ark.[24] yüz bulma için yüzsel kısım yanıtlarından yararlanarak bir derin öğrenme yaklaşımı sunmuşlardır. Bu çalışmada, yüz bulma için bir DNN(Deep Neural Network) dizaynı yapılmıştır. Faceness-Net diye isimlendirdikleri yüz önerisi ve yüz bulma yaklaşımının edinme yolu 3 evreden oluşmaktadır. Partness mapler üretme, faceness skorlarıyla aday pencereleri sıralama ve yüz bulma için yüz önerileri artırmaktır. Yüz sınıflandırma ve sınırlayıcı kutu gerilemesinin birlikte yürütüldüğü bu çalışmada, 7 evrimsel ve 2 max-pooling katman içeren bir ağ kullanılmıştır. Çalışma FDDB, AFW ve PASCAL face gibi veri setlerinde %90.95 gibi bir oranda geri çağırma sağlamıştır. H. Qin ve ark.[25], yüz bulma için basamak CNN ortak eğitimi önerirler. Bu çalışmada CNN basamak için end-to-end optimizasyon basamak için birleşimli eğitim önerilmiştir. AFLW, LFW, PASCAL VOC2012 veri setlerinde test edilen yöntem kabul edilebilir doğruluk oranları sağlamıştır.

K. Yadhu ve ark.[26], video veri seti ile yüz bulma ve tanıma yapan bir yöntem önerirler. Yüz bulma için Viola-Jones algoritması kullanırken, aydınlatma, gürültü ve kararlılık gibi bulmayı önleyen faktörlerle mücadele etmek için ön işlem adımları olarak sırasıyla; doyurma, median filtreler ve süper kararlılık uygulanır. Yüz bulma işleminin ardından özellik çıkartma işlemi için haar-wavelet kullanılır ve yüz tanıma işlemi için

CNN kullanılır. Bu yöntem Youtube celebrities adlı veri setinde %93.75 ortalama bulma oranı gösterir.

K. H. Kong ve ark.[27], yüz bulmak için önerdikleri yöntemde, aydınlatma değişiklikleri gibi harici faktörlere karşı LGP'yi(Yerel Derece Deseni) kullanarak simetriyi ve değişmemeyi geliştiren S-LGP(Simetri Düzgün Yerel Derece Deseni) ve U-LGP(Tekdüzen Yerel Derece Deseni) yöntemlerini kullanır. Yüz ifadesi, arkaplan vb. LBP(Yerel İkili Desen)'den önce giriş görüntüsünü ve cilt rengi ayıklama yöntemini kullanarak, YCbCr uzayında pozitif yüzü toplama ve incelemekten xml dosyalarını oluşturan basamak sınıflayıcı eğitimi çıkarıcı kullanarak örnekleme ve negatif yüz örneğini 1:2 oranla analiz eder ve CNN derin öğrenme algoritmasını kullanır.

X. Sun ve ark. [28], derin öğrenme teknikleri kullanarak yüz bulma için yeni bir yöntem önerir. Özellikle, jenerik nesne algılama için kullanılan RCNN çerçevesini genişletir ve özellik birleştirmesi, çok ölçekli eğitim, sabit negatif madencilik, vb. dahil olmak üzere yüz tanıma görevlerini çözmek için daha hızlı RCNN algoritmasını geliştirmeye yönelik birkaç strateji önerirler.

K. Zhang ve ark. [29], çalışmalarında yüz bulma performansını artırmak için algılama ve hizalama arasındaki doğal bağıntıyı kullanan derin kademeli çok görevli bir çerçeve önerir. Çerçeve, kademeli ve hassas bir şekilde yüz ve yer işareti konumunu tahmin etmek için dikkatle tasarlanmış derin katlama ağlarının üç aşamalı kademeli bir mimariyi harekete geçirir. Buna ek olarak, pratikte performansı daha da artıran yeni bir çevrimiçi zor örnek madencilik stratejisi önerirler. Yöntem, zorlu yüz tanıma verileri seti ve karşılaştırma testi ve yüz tanıma için WIDER FACE yüz ifadelerine dikkat çeken gerçek tekniklerle karşılaştırıldığında üstün doğruluk sağlarken gerçek zamanlı performansı korur.

Tablo 1.1'den görülebileceği gibi yüz bulma işlemi için var olan yöntemler dört kategoriye ayrılabilir. Literatürde var olan derin öğrenme teknikleri kullanılarak geliştirilen yöntemler ile yapılmış yüz bulma algoritmaları, bahsettiğimiz diğer yüz bulma yöntemlerinin aksine yüz kapanıklığı, poz değişikliği, ışığın etkisi gibi faktörlere karşı dayanıklı çözümler sunmaktadır. Bu sebeplerden dolayı tezimizde yüz bulma işlemi için derin öğrenme mimarisi olan evrimsel sinir ağları kullanılmıştır.

Tablo 1.1. Yüz Bulma için literatürde kullanılmış olan yöntemlerin kategorilerine göre sınıflandırılması

Kategori	Yöntem	Özellikler	Yapılmış Bazı Çalışmalar
Bilgi-Tabanlı Yaklaşım		Tek başına çok sınırlıdır. Uygun bir kurallar dizini oluşturmak çok zordur.	[43, 44]
Özellik-Değişmez Tabanlı Yaklaşım	Ten Rengi	Göz, burun ve ağız genişliği, kaş kalınlığı, yüz genişliği, yanaklar, ten rengi özellik olarak yüzü temsil eder. Özellik tabanlı yaklaşım şablon tabanlı yöntemlere göre daha az hafıza ihtiyacı duyar, daha hızlı ve kısa sürede tanıma yapar [45].	[2, 3, 4, 5, 6]
	Çoklu Özellikler		[50]
	Doku		[51]
	Yüz Özellikleri		[13, 14, 15, 16]
Görünüm-Tabanlı Yaklaşım	Özyüz	Şablon eşlemesinin aksine, modeller (veya şablonlar), yüz görünümünün temsil değişkenliğini yakalaması gereken bir dizi eğitim görüntüsünden öğrenilir. Daha sonra bu öğrenilen modeller algılama için kullanılır. Bu yöntemler esas olarak yüz tanıma için tasarlanmıştır[46].	[48,49]
	Yapay Sinir Ağı		[17, 18, 19, 20, 52,53]
	Evrişimsel Sinir Ağı		[24,25, 26, 27, 28, 29]
	DVM		[7, 8, 9, 10, 11,12]
	Dağıtım-tabanlı		[54]
	Naif Bayes Sınıflandırıcı		[55]
	Saklı Markov Modelleri		[56, 57]
Şablon-Eşleme Tabanlı Yaklaşım	Ön tanımlı Yüz Şablonu	Geleneksel şablon uyumu, yüz tanıma için mesafe metriğini kullanmak gibidir; bu, sembolik şablonların veya her sınıfın bir takımını seçmek demektir, benzerlik ölçümü, bir test görüntüsü ile her sınıf arasında hesaplanır ve en yüksek benzerliği olan sınıf skor, doğru eşleme olarak seçilir[47].	[58, 59]
	Deforme Olabilen Şablonlar		

Yüz tanıma problemi biyometri ve bilgisayar görmesi gibi birçok alanın ilgilendiği çalışma konusudur ve uzun yıllardır birçok çalışma yapılmıştır. İstatiksel yaklaşım tabanlı(PCA, LDA, ICA, K-PCA, DCT), özellik tabanlı denkleştirme, şablon eşleme ve sinir ağı tabanlı(saklı markov modelleri, bulanık mantık, gabor filtresi, derin öğrenme) yaklaşımlar, yüz tanıma probleminin çözümünde kullanılan yaklaşımlardır.

Y. Zhang ve ark. [86], yüz tanıma işlemi için adaptif evrimsel sinir ağı modelini önerir. Geleneksel CNN’de ağı yapısı oluşturulurken performans kıyası yapılır ve işleme en uygun yapı deneme yanılma yolu ile bulunur. Adaptif CNN’de ise bir kollu yapı ile ağ başlatılır. Sistem ortalama hatası ve eğitim örneklerinin tanıma oranı CNN’nin yapısının genişlemesini kontrol etmek için düzenlenir. Ağ şart sistem ortalama hatasını sağlayana kadar küresel genişlemeyle genişler. Son olarak CNN yapısı otomatik olarak tanımlanır. Bu yapıda, aynı zamanda yeni örnekler için ek öğrenme, orijinal ağ değiştirilmeden tutulurken yeni dallar eklenerek başarılabılır. Yöntem ORL yüz veri setinde test edilmiş ve yüksek başarı oranı sağlamıştır.

S. Sharma ve ark. [30] dlib kütüphanesi kullanarak C++ dilinde yüz tanıma için yeni bir yöntem önermiştir. Burun ve üst dudakların yüzsel işaretlerini bularak ön yüzleri bulmak için bilgisayar görmesi teknolojisini kullanmışlardır. Yüz hizalamayı Dlib kullanarak yaparken özellik çıkartımı ve yüz tanıma için CNN kullanmışlardır.

W.Zhao ve ark.[31] PCA ve LDA tabanlı bir yüz tanıma yöntemi tanımlamıştır. İki aşamadan oluşan yöntemin birinci aşamasında yüz görüntüsünü orijinal vektör uzayında bir yüz alt uzayınca PCA yoluyla, ikinci olarak da en iyi doğrusal sınıfı elde etmek için LDA kullanmışlardır.

F. Schroff ve ark.[32] yüz imgelerinden mesafelerin doğrudan yüz benzerliği ölçüsüne karşılık gelen kompakt Öklid uzayına doğrudan bir eşlemeyi öğrenen FaceNet adlı bir sistem sunmuştur. Bu alan üretildikten sonra, yüz tanıma, doğrulama ve kümeleme gibi görevler, özellik vektörleri olarak FaceNet gömümleri ile standart teknikler kullanılarak uygulanabilmektedir. Metot, önceki yaklaşımlarda olduğu gibi ara darboğazdan ziyade doğrudan gömülmeyi optimize etmek için eğitilmiş derin konvolüsyonel bir ağ kullanmaktadır.

E. Zhaou ve ark. [33] Megvii Yüz Tanıma Sistemini kurmuşlardır. Tanıma işlemi için 10 katmanlı derin evrimsel ağ modeli dizayn edilmiş ve temsil çıkarma için dört yüz

bölgesi kırılmıştır. Geleneksel çok sınıflı sınıflandırıcı iskeleti altında MFC verisiyle ağı eğitmişlerdir. Test aşamasında, özellik azaltma için bir PCA modeli uygulanmış ve test yüz çiftini ölçmek için basit bir L2 norm kullanılmıştır.

Y. Sun ve ark. [34], yüz tanıma için DeepID3 olarak adlandırılan iki çok derin sinir ağı mimarisi önermiştir. Bu iki mimari, yüz tanımaya uygun hale getirmek için VGG net [35] ve GoogLeNet [36] 'da önerilen yığılmış evrişim ve başlangıç katmanlarından yeniden oluşturulmuştur. Ortak yüz tanıma doğrulama denetim sinyalleri eğitim sırasında ara ve son özellik çıkarma katmanlarına ilave edilir. Önerilen iki mimarinin bir topluluğu, sırasıyla, 99: 53% LFW yüz doğrulama doğruluğunu ve % 96: 0 LFW derece -1 yüz tanımlama doğruluğunu sağlıyor.

T. Ahonen ve ark. [37], yerel ikili model (LBP) doku özelliklerine dayanan bir yüz görüntü sunumunu sunmuştur. LBP, yüz görüntüsünün küçük bölgelere bölünmesi ve yerel ikili kalıplar kullanılarak her bölgenin tanımının hesaplanmasına dayanır. Bu tanımlayıcılar daha sonra, mekânsal olarak zenginleştirilmiş bir histogram veya özellik vektörüne birleştirilir. Tek bir bölgenin doku tanımı bölgenin görünümünü açıklar ve tüm bölge açıklamalarının birleşimi yüzün genel geometrisini kodlar. Yüz imgesi, LBP özellik dağılımlarının çıkarıldığı ve yüz tanımlayıcısı olarak kullanılmak üzere geliştirilmiş bir özellik vektörüne birleştirildiği birkaç bölgeye ayrılmıştır.

J. Lu ve ark. [38], görüntü yamalarından ayırt edici özellikler öğrenerek yeni bir ayrımcı multimanifold analizi (DMMA) yöntemini önermiştir. Birincisi, kişi başına her numune için bir görüntü seti oluşturmak için kayıtlı her yüz görüntüsünü birbiriyle örtüşmeyen birkaç yamaya bölmüş, ardından SSPP yüz tanımayı çeşitli-çeşitli eşleştirme problemi olarak formüle etmiş ve farklı kişilerin çeşitli kenar boşluklarını en üst düzeye çıkarmak için birden fazla DMMA özellik uzayı öğrenmişlerdir. Son olarak, etiketsiz konuları tanımlamak için yeniden yapılandırmaya dayalı çeşitli-çeşitli mesafesini sunmuşlardır.

R. Dellena ve ark. [39], kişi başına tek bir eğitim örneği kullanılarak gerçek yüz tanımda mevcut kısmi tıkanıklık bozulmalarıyla mücadele yaklaşımı sunmuşlardır. İlk olarak, orijinal görüntüler çoklu bloklara bölünür ve Yerel İki Renkli Modeller, her bir blok üzerinde ayrı ayrı bir yerel tanımlayıcı olarak uygulanır. Daha sonra, ortaya çıkan tanımlayıcıların bir boyut azalması K-PCA kullanılarak gerçekleştirilir. Bir kez bittiğinde, rasgele yamaları seçmek için rasgele bir örnekleme yöntemi kullanılır ve bu nedenle birkaç alt-SVM sınıflandırıcısı kurar. Son olarak, her alt sınıflandırıcıdan alınan sonuçlar, tanıma performansını artırmak için birleştirilir.

S. Guo ve ark.[40], yüzleri tanımak için Evrişimsel Sinir Ağı ve Destek Vektör Makinesini birleştirmiştir. CNN, dikkat çekici özellikleri otomatik olarak elde etmek için bir özellik çıkarıcı olarak kullanılmıştır. Öncelikle güncellenmiş ağırlıkları almak için CNN yardımcı verilerle önceden eğitilmiş ve ardından daha gizli yüz özelliklerini çıkarmak için hedef veri kümesine göre CNN eğitilmiştir. Sonunda tüm sınıfları tanımak için CNN yerine sınıflandırıcı olarak SVM kullanılmıştır. CNN'den çıkarılan yüz özelliklerinin girişi ile SVM, yüz görüntülerini daha doğru tanımıştır.

O. M. ark.[41] kendisinden önceki yüz tanıma yöntemlerine iki katkı sağlamıştır: İlk olarak, çok büyük ölçekli bir veri kümesinin (2,6 K'dan fazla kişinin 2.6 M'lık görüntüleri) döngü içinde otomasyon ve insan birleşimi tarafından nasıl bir araya getirilebileceğini ve veri saflığı ile zaman arasındaki ticareti tartışmayı göstermiş; İkincisi, standart LFW ve YTF yüz karşılaştırma testlerinde karşılaştırılabilir nitelikte bir sonuç elde etmek için yöntemleri ve prosedürleri sunmak için derin ağ eğitiminin ve yüz tanımanın karmaşıklıklarını incelemişlerdir.

H. Khalajzadeh ve ark. [42] , bir evrişimsel sinir ağı (CNN) ve bir Lojistik regresyon sınıflandırıcısı (LRC) birleştirilen bir karma sistem sunmuştur. Bir CNN yüz görüntülerini algılamak ve tanımak için eğitilir ve konvolüsyon ağı tarafından öğrenilen özellikleri sınıflandırmak için bir LRC kullanılır. CNN kullanarak normalize edilmiş verilere öznitelik çıkarımı uygulamak, sistemin poz ve aydınlatma varyasyonlarına maruz kalan yüzlerle baş etmesine neden olur. Ayrımcı bir sınıflandırıcı olan LRC, yüz görüntülerinin çıkarılmış özelliklerini sınıflandırmak için kullanılır. Ayrımcılık analizi, normallik varsayımları yerine getirildiğinde daha verimli olur.

Tablo 1.2'de yüz tanıma ile ilgili literatürde var olan çalışmalar kategorilerine göre ayrılarak yöntemlerle ilgili yapılan çalışmalardan bazıları gösterilmiştir.

Tablo 1.2. Yüz tanıma için literatürde bulunan yöntemlerin özeti

Kategori	Yöntem	Özellikler	Yapılmış Bazı Çalışmalar
Bütüncül (Holistic) Tabanlı Yaklaşımlar	PCA	Bu yaklaşımlar, yüzlerin yerel özelliklerinden ziyade küresel gösterimleri, yani resmin tamamına dayalı açıklamaları kullanarak yüzleri tanımlamaya çalışmaktadır [60]. Bütüncül yaklaşımların en büyük avantajı, yalnızca sınırlı bölgelere veya ilgi noktalarına yoğunlaşarak görüntülerdeki hiçbir bilgiyi yok etmemesidir.	[31, 33, 66]
	LDA		[31]
	ICA		[63]
	K-PCA		[39]
	Adaboost		[62]
	CNN		[30, 32, 34, 40, 41, 86]
	SVM		[39, 40]
	Fuzzy Logic		[64]
	Dalgacık Dönüşümü		[65]
Özellik Tabanlı	LBP	Bu yaklaşımların en büyük dezavantajı, otomatik özellik algılamanın zorluğudur ve bu tekniklerden herhangi birinin uygulayıcısının hangi özelliklerin önemli olduğu konusunda keyfi kararlar vermesi gerektiği gerçeğidir [61].	[37]
	Gabor Dalgacık		[66]
Şablon Eşleme	AAM (Active Appearance Model)	Şablon eşleme kategorisi, her bir etiket sınıfı için birkaç şablon oluşturur ve uygun bir karara ulaşmak için bu şablonları test deseniyle karşılaştırır [47].	[67]
Kısmi-Tabanlı	SIFT	Kısmi tabanlı yöntemler, yüz tanımından önemli parçalar algılar ve parça görünüşlerini tanıma için makine öğrenme araçlarıyla birleştirir [47].	[68]

1.2. Tezin Amacı ve Kapsamı

Yüz ayırt etme ve tanıma konuları uzun yıllardır popülerliğini koruyan, birçok araştırmacının ilgisini çekerek çalıştığı konulardır. Özellikle güvenlik sistemleri için el,

iris, parmak izi gibi diğer ayırt edici yöntemlere nazaran daha kullanışlı olması dolayısı ile çokça tercih edilmektedir. Yıllardır sürekli farklı yöntemler geliştirilerek, sistemin daha doğru sonuçlar vermesi ve hızlı yanıt verme gibi esasların iyileştirilmesine çalışılmaktadır.

Son yıllarda yapay sinir ağlarının gizli katman sayısının artırılmış bir türevi olarak da düşünebileceğimiz, genel olarak “derin öğrenme” olarak isimlendirilen yöntem, çoğu makine öğrenmesi probleminde olduğu gibi yüz ayırt etme ve tanıma konularında da son teknoloji başarı göstermektedir.

Bu tez çalışmasının amacı, son zamanlarda birçok konudaki problemleri çözmede başarı sağlamış olan derin öğrenme tekniğini ve bir derin öğrenme mimarisi olup özellikle görüntü tanıma ve sınıflandırmada başarılı olan evrimsel sinir ağlarını incelemektedir. Ayrıca bu tez çalışmasında evrimsel sinir ağları kullanılarak yüz ayırt etme ve tanıma işlemleri yapılması amaçlanmaktadır.

1.3. Tezin Yapısı

Bu tez çalışması *giriş bölümü* ile birlikte beş bölümden oluşmaktadır. Bu bölümde tez çalışması kapsamında literatür çalışması yapılarak, yüz ayırt etme ve tanıma işlemleri için geliştirilen yöntemler incelenmiştir.

İkinci bölümde, derin öğrenme teknolojisi açıklanarak, derin öğrenme mimarileri olan otomatik kodlayıcılar, kısıtlı boltzman makineleri ve evrimsel sinir ağları anlatılmıştır.

Üçüncü bölümde, yüz bulma işlemi için derin öğrenme tabanlı bir yaklaşım sunulmuştur. Yüz bulma işlemi yapılırken caffe kütüphanesi ve GPU teknolojisinden faydalanılmıştır.


Dördüncü bölümde, yüz tanıma işleminin gerçekleştirilmesini sağlayan bir yaklaşım sunulmuştur. Yüz tanıma edinme yolu; Yüz bulma, özellik çıkartma ve yüz tanıma adımları izah edilerek yöntem gerçekleştirilmiştir.

Beşinci bölüm ise tezin son kısmıdır ve burada tezde yapılan çalışmalar değerlendirilerek gelecek çalışmalar için öneriler sunulmuştur.

2. DERİN ÖĞRENME

Son yıllarda, sinir bilimcilerin ve akademik çevrelerin yapmış olduğu çalışmalar sonucunda elde edilen bilgiler ile makine öğrenme konusunda önemli ilerlemeler kaydedilmiştir. Yapay sinir ağlarının, çok katmanlı yapıların işleme ve sınıflandırılması gibi problemlerde yetersiz kalmasının ardından, donanım kısıtlarının da giderilmesiyle, birçok katman ve değişkenden oluşan, genel olarak “derin öğrenme” denen mimariler ortaya çıkmıştır. Derin öğrenme algoritmaları, yapay sinir ağları kökenli ve enerji tabanlı modellerinden oluşmaktadır.

Derin öğrenme, verinin doğrusal olmayan dönüşümünü sağlamaktadır. Sığ yapılar yerine Gauss karışım modelleri, saklı Markov modelleri, koşullu rassal alanlar, çok katmanlı yapı ile karmaşık ilişkileri modelleyebilmektedir. Şekil 2.1’de derin öğrenme sinir ağı yapısı verilmektedir. En çok kullanılan derin öğrenme mimarileri; Otomatik kodlayıcılar, Kısıtlı Boltzman Makineleri ve Evrimsel Sinir Ağlarıdır [69].




Şekil 2.1. Derin öğrenme sinir ağı yapısı

2.1. Otomatik Kodlayıcılar (Autoencoders)

Otomatik kodlayıcı, girişini çıktısına kopyalamak üzere eğitilmiş bir sinir ağıdır. Genellikle yalnızca yaklaşık kopyalamalarını ve eğitim verilerini andıran girdilerini

kopyalamalarını sağlayan yöntemlerle sınırlandırılırlar. Model, girdinin hangi yönlerinin kopyalanmasını gerektiğini önceliklendirmeye zorlandığından, çoğu kez verilerin yararlı özelliklerini öğrenir.

Otomatik kodlayıcı sinir ağları, bazı istenen özelliklere sahip olmak için gösterimi sınırlarken, kodlanmış gösteriminden girdiyi yeniden yapılandırmaya dayalı denetlenmeyen bir öğrenme algoritması ile eğitilir. Otomatik kodlayıcılara dayanan derin ağlar, önceden eğitim görmüş otomatik kodlayıcıyı katmana istifliyerek ve ardından denetlenen ince-ayar algoritması izleyerek oluşturulur [70].




Şekil 2.2. Örnek otomatik kodlayıcı ağ yapısı

Şekil 2.2’de örnek bir otomatik kodlayıcı yapısı verilmektedir. Yapıda gizli katman sayısı sınırlı tutularak veriler üzerinden ilginç yapı keşfedilebilir. Gizli katman sayısının giriş katmanındaki düğüm sayısından fazla olduğu durumlar da olabilmektedir. Amaç, girişe benzer çıkış elde etmek için otomatik kodlayıcı kimlik işlevine bir yaklaşma öğrenmeye çalışır [69].

2.2. Kısıtlı Boltzman Makinası (KBM)

Boltzman makineleri (BM) logaritmik Markov rastgele alanlarının özel bir formudur. Geoff Hinton tarafından geliştirilen KBM, sınıflandırma, regresyon, özellik öğrenimi ve boyutsal küçültme için kullanışlı bir algoritmadır. KBM'ler derin inanç ağlarının yapı taşlarını oluşturan sıg, ileri katmanlı, birer adet gizli ve görünür katmandan ibaret basit bir yapıya sahip olan sinir ağlarıdır.



Şekil 2.3. KBM ağ yapısı

Şekil 2.3'de KBM ağ yapısı verilmektedir. İlk katman olan görünür katmanı dört düğüm, gizli katman üç düğümden oluşmaktadır. İki katmana ait herbir düğüm diğer katmandaki düğümlerle bağlıdır. Aynı katmana ait düğümler kendi aralarında iletişim kurmazlar. Aynı katmandaki düğümlerin birbirleri ile bağlandıkları yapı ise Boltzmann Makinesi (BM) olarak bilinmektedir. KBM, aradaki bağlantıların çıkartılarak BM'nin basitleştirilmiş halidir [71].

Kısıtlı Boltzmann makinesinin katmandaki ağların kendi aralarında bağlantılarının olmamasıdır. Her düğüm girdiyi işleyerek iletip iletmeyeceğine kendisi karar verir. Her düğümün sahip olduğu piksel değeri ayrı bir ağırlık değeri ile çarpılıp toplandıktan sonra

bias değeri eklenir ve aktivasyon fonksiyonundan geçirilerek çıktı oluşturulur. KBM'nin yapısı, simetrik ikili ve çift yönlü çizgedir.

2.3. Evrişimsel Sinir Ağları (CNN)

Evrişimsel sinir ağları, derin öğrenme mimarilerinden olup araştırmacılarca yaygın bir şekilde kullanılmaktadır. Bu kısımda, ağın genel yapısı ve mimarisi anlatılmaktadır.

2.3.1. Motivasyon

Evrişimsel ağlar, maymunun görsel korteksinin yerel açık alanından türetilmiştir. Maymunlar tanıdık yüzler gösterildiğinde, beyinleri belirli bir bölgede yanar. Maymun görsel sistemindeki alıcı hücreler “reseptive field” olarak adlandırılan görsel alanın küçük alt bölgelerine duyarlıdır. Buna karşın evrişimsel ağlarda, görüntüdeki yerel alıcı alanlar ilk gizli katmanlardaki bireysel nöronlara bağlanır. CNN'ler komşu nöronlar arasında mekânsal olarak yerel ilgileşim kullanır. Katmanları yerel bir bağlantı modeli kullanarak öğrenirler. Böylece öğrenilen filtreler mekânsal olarak yerel giriş desenine en güçlü cevabı verir [72].


Evrişimsel sinir ağları, bir biyoloji ve matematik kombinasyonu gibi görünmesine rağmen bilgisayar görme alanında en etkili yeniliklerden bazıları olmuştur. Alex Krizhevsky, 2012 yılında görüntü sınıflandırma yarışması olan ImageNet yarışmasını kazanmak için evrişimsel sinir ağlarını kullanmış ve sınıflandırma hata kaydını % 26'dan % 15'e düşürmüştür [73]. O zamandan beri, derin öğrenme birçok şirketin dikkatini çekmiş ve bir dizi şirket, hizmetlerinin temelinde derin öğrenme kullanmaya başlamıştır.

CNN, ileri beslemeli olup bulmada çok etkili bir yöntemdir. Yapısı basittir; daha az eğitim parametresi ve uyarlanabilirlik gibi birçok özelliğe sahiptir. Onun ağırlık paylaşımlı ağ yapısı onu biyolojik sinir ağlarıyla daha benzer yapmıştır. Bu sayede ağ modelinin karmaşık yapısı ve ağırlık sayısı azaltılır. CNN, bilim ve akademik çevrelerince, sinyal işleme, doğal dil işleme, robotik ve ses işleme gibi birçok alanda kullanılmaktadır. Fakat en popüler olduğu alan, görüntü işleme ve desen bulmadır.

2.3.2. Mimari

Evrişimsel sinir ağı, sıradan sinir ağına çok benzemektedir. Öğrenilebilir ağırlıklar ve biaslar içeren nöronlardan oluşur. Her nöron bazı girdileri alır, bir nokta ürünü üretir ve isteğe bağlı olarak doğrusal olmayan bir şekilde takip eder. Bütün ağ, türevlenebilir bir skor fonksiyonu ifade eder. Bilinen sinir ağlarında olduğu gibi evrişim sinir ağı da son katmanında softmax gibi bir kayıp fonksiyonu içerir .


Evrişimsel ağlar, sinir ağlarından katmanların biçim ve işlevleri açısından farklılık gösterir. Sıradan sinir ağlarında katmanlar tek boyutludur ve bu katmandaki nöronlar tamamen bağlıdır. Diğer taraftan, CNN’lerdeki katmanların biçimi genellikle genişlik, yükseklik ve derinlik parametreleri ile üç boyutludur [74].



Şekil 2.4. Sıradan sinir ağı yapısı


Şekil 2.4’de tam bağlantılı ileri beslemeli sıradan bir ağ verilmektedir. Ağın ilk gizli katmanındaki bütün nöronların her bir pikseline bağlantı vardır. Şekil 2.5’de verilmiş olan CNN mimarisinde, gizli katmanın her nöronu görüntünün sadece yerel bölgelerine bağlanır. Giriş görüntüsündeki bu bölgeye “yerel açık alan” denir. Ağırlık ve biaslar açık

alanlarca paylaşılır. Bu ilk gizli katmandaki bütün ağırlıklar ve bias aynı fakat farklı yerel alan pikselleriyle bağlı demektir.



Şekil 2.5. Evrişimsel sinir ağı yapısı

Evrişimsel sinir ağları, sadece iki boyutla kısıtlı değildir. Ses verisi için tek boyut ağ kullanılabılırken, gereken durumlar da üç boyutlu ağ da kullanılabılır. Evrişimsel sinir ağı, belirli özellikleri (diğer bir deyişle şekilleri) algılayan çekirdekleri (filtreler) seçecektir. Özellikler, kenarlar gibi basit veya göz gibi karmaşık olabilir. Sinir ağı gibi, evrişimsel ağları katmanlara yerleştirebilirsiniz; burada daha derin katmanlardaki filtreler daha karmaşık özellikleri algılayabilir.




Şekil 2.6. Havuzlama, evrişim ve tam bağlı katman içeren örnek bir evrişimsel sinir ağı modeli

Şekil 2.6’da havuzlama, evrişim ve tam bağlı katman içeren basit bir evrişimsel sinir ağı modeli verilmektedir. CNN’ler çoğunlukla birçok kısımdan oluşmaktadır. Bu kısımlar;

evrişim, aktivasyon, havuzlama ya da alt örnekleme ve tam bağlantılı katmanlardır. Bütün kısımlar ayrı alt başlıklarda aşağıda anlatılmıştır.

2.3.2.1. Evrişim Katmanı

Evrişim katmanının birincil amacı, girdi görüntüsünden özellikleri çıkarmaktır. Evrişim matrisi, bir matrisin “çekirdek” olarak adlandırılan başka bir matriste uygulanmasıdır. Evrişim matrisi filtresi, ilk olarak işlenecek görüntüyü kullanır. Konvolüsyon, girdi verisinin küçük karelerini kullanarak görüntü özelliklerini öğrenerek pikseller arasındaki mekânsal ilişkiyi korur. Evrişim işlemi yapılırken genelde 5x5 veya 3x3'lük matrisler kullanılır ve istenilen tüm etkiler için yeterlidir.



Şekil 2.7. Evrişim katmanında uygulanan evrişim işlemi


Şekil 2.7. evrişim operasyonunun nasıl işlem yaptığını vermektedir. CNN terminolojisinde, 3x3 matrisine 'filtre' veya 'çekirdek' adı verilir ve filtreyi görüntü üzerinde kaydırarak oluşturulan matrise “Özellik Haritası” denir. 6x6 boyutlu bir görüntü 3x3 boyutlu filtreden 1 adım (stride) ile geçirilmektedir. Filtreleme sonucu oluşturulan özellik haritası (görüntü boyutu- Filtre boyutu+ adım miktarı = özellik haritası boyutu) formülünden $6-3+1=4$ 4x4 boyutuna inmektedir [75].

Bir CNN, eğitim süreci sırasında filtrelerin değerlerini tek başına öğrenir fakat yine de, eğitim sürecinden önce filtre sayısı, filtre boyutu, ağ mimarisi gibi parametreler belirtilmelidir. Sahip olduğumuz filtre sayısı arttıkça, daha fazla resim özelliği ayıklanır ve

ağımız görünmeyen resimlerde kalıpları tanımada daha iyi olur. Evrişimsel sinir ağları yapısının ilk katmanı olan evrişim katmanının ardından aktivasyon işlemi olmaktadır.

2.3.2.2. Aktivasyon Katmanı

Her evrişim katmanından sonra, doğrusal olmayan bir katmanın (veya etkinleştirme katmanının) hemen sonra uygulanması söz konusudur. Bu katmanın amacı, temelde evrişimsel katmanları sırasında doğrusal işlemler hesaplayan bir sisteme doğrusal olmayanlık getirmektir [76]. Aktivasyon katmanında, fonksiyon hücreye gelen net girdiyi işler ve hücrenin bu hücreye karşılık üreteceği değeri belirler. Hücre modellerinde hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit ya da uyarlanabilir parametrelili seçilebilir.




Şekil 2.8. Evrişim sinir ağı modelinde en çok kullanılan aktivasyon fonksiyonları

Şekil 2.8 en çok kullanılan aktivasyon fonksiyonlarını vermektedir. Evrişimsel sinir ağları modellerinde, geçmişte tanh, sigmoid gibi doğrusal olmayan fonksiyonlar kullanılmış fakat araştırmacılar, ağ, hesaplamalı etkinlik nedeniyle daha hızlı işlem yapabildiğinden ReLU katmanlarının daha iyi çalıştığını keşfetti. Ayrıca, eğimin katmanlar vasıtasıyla katlanarak azalması nedeniyle ağın alt katmanlarının çok yavaş ilerlediği sorun olan kaybolma eğrisi probleminin hafifletilmesine yardımcı olur. ReLU katmanı, giriş

hacmindeki tüm değerlere $f(x) = \max(0, x)$ fonksiyonunu uygular [77]. Temel terimlerle bu katman, tüm negatif etkinleştirmeleri yalnızca 0'a değiştirir. Bu katman, evrişim katmanının alıcı alanlarını etkilemeksizin modelin ve genel ağın doğrusal olmayan özelliklerini artırır.

2.3.2.3. Havuzlama Katmanı

Evrişimsel ağlar mimarisinde, birbiri ardına evrişim katmanları arasında periyodik olarak bir havuzlama katmanı eklemek sık görülür. Bu kısımda havuzlama katmanının yerini alt-örnekleme katmanının aldığı modeller de bulunmaktadır. İşlevi, ağdaki parametrelerin ve hesaplamanın miktarını azaltmak ve dolayısıyla aşırı uygunluğu kontrol etmek için temsilin uzamsal boyutunu aşamalı olarak azaltmaktır.



Üretilmiş özellik haritası

Şekil 2.9. 2x2 filtre ve 2 adım ile max-havuzlama işlemi

Şekil 2.9'da maksimum havuzlama işlemi verilmektedir. Havuzlama Katmanı, girişin her derinlik diliminde bağımsız olarak çalışır ve maksimum işlemini kullanarak uzamsal olarak yeniden boyutlandırır. En yaygın form, genişleme ve yükseklik boyunca girişteki her bir derinlik diliminin 2 alt örneği halinde bir adımla uygulanan 2x2 boyutlu filtreleri olan bir havuz katmanı olup, aktivasyonların% 75'i atılmaktadır. Derinlik boyutu değişmeden kalır.

Şekil 2.6’da verilen ağ modelindeki giriş görüntüsünün 64x64 boyutlu olduğunu varsayarsak, ilk evrişim işlemi sonrası 5x5 boyutlu filtreler uygulandığında yeni boyut 60x60 olur. ReLU katmanı sonrası modelin ve genel ağın doğrusal olmayan özellikleri artırılır. Maksimum havuzlama katmanında 60x60’lık görüntüye 2x2 boyutlu filtre ile adım sayısı 2 olacak şekilde havuzlama işlemi yapılır ve görüntünün yeni boyutu yarıya inerek 30x30 olur. Sonraki evrişim + ReLU + havuzlama katmanında ilk katmanlarındaki aynı işlem tekrarlanır. İkinci havuzlama katmanı sonrasında görüntünün yeni boyutu 14x14 olur. Bundan sonraki katman ise bütün nöronların bağlı olduğu tam bağlı katmandır.

2.3.2.4. Tam Bağlı Katman


Tam Bağlı katman, çıktı katmanında softmax ve SVM gibi sınıflandırıcılar kullanan geleneksel bir Çok Katmanlı Algılayıcıdır. "Tam Bağlı" terimi, önceki katmandaki her nöronun bir sonraki katmandaki her bir nörona bağlandığını ifade eder. Çok Katmanlı Algılayıcılara çok benzemektedir [84].

Evrişim ve havuz katmanlarının sonucunda oluşan çıkış, girdi resminin üst düzey özelliklerini temsil eder. Evrişim ve havuz katmanlarının sınıflandırma için tahmin yapma durumu yoktur. Tam Bağlı katmanın amacı, bu özelliklerin, eğitim verisi setine dayalı olarak çeşitli sınıflara girdi görüntüsünü sınıflandırmak için kullanılmasıdır.

Şekil 2.6’da görüldüğü üzere tam bağlı katmanda 4 ağ bulunmaktadır. Bu nöronların her biri bir sınıfı temsil eder. Bunların; ev, bisiklet, araba, kamyon olduğunu varsayalım. Ağ burada çıkartılan özniteliklere bakarak giriş verisinin hangi sınıfa daha yakın olduğuna bakar ve sonuç olarak bir sınıf döndürür. Doğru eğitilmiş bir ağ ev değerini döndürecektir.

3. EVRİŞİMSEL SINIR AĞI TABANLI YÜZ BULMA YAKLAŞIMI

Tez çalışmasının bu bölümünde, evrişimsel sinir ağı tabanlı bir yüz bulma yaklaşımı önerilmektedir. Yüz veri seti AFLW(Annotated Faces Landmarks in the Wild) [78]'deki görüntüler kullanılarak eğitim sürecinin gerçekleştirildiği yöntemde, veri artışı için HOG-Linear SVM bulucusu ve CNN bulucularının performansını ölçmede kullanılan IoT(Intersection over Union) metriği kullanılmaktadır. IoT değerinin %50'den büyük olduğu görüntüler yüz olarak kabul edilerek pozitif eğitim verisi dosyasına atılırken, kalanlar negatif görüntü dosyasına atılmaktadır. Elde edilen görüntüler 227x227'ye yeniden boyutlanmaktadır.



Şekil 3.1. Yüz bulma işlemi edinme yolu

Şekil 3.1' de yüz bulma yaklaşımının edinme yolu verilmektedir. Görüntü ön işlemlerinden geçirildikten sonra özellik çıkartmak için, model olarak Alexnet modeli ince ayar verilerek kullanılmaktadır. İnce ayarlı derin ağ modeli kullanılarak kayan pencereler yöntemi ile son yüz bulucu elde edilmektedir.

3.1. Veri Seti

Bir modelin eğitimi için kullanılan görüntülerin özellikleri ve boyutu, öğrenme oranının kabul edilebilir olması ve doğru sonuçlar elde edilebilmesi açısından önem arz etmektedir. Eğitim için kullanılan görüntü sayısının fazla olması, modelin öğrenmesini olumlu yönde etkilemektedir.

İnternet ortamında birçok görüntü kaynağına erişimin olması ve büyük veri teknolojisinin ilerlemesi erişime açık birçok büyük veri setinin oluşturulmasına imkân vermektedir. Yüz bulma problemi için geçmişten günümüze birçok yöntem geliştirilmektedir. Yöntemlerin, tıkanıklık, aydınlanma, poz değişikliği gibi bulmayı önleyici faktörlere karşı da dayanıklı olması gerekmektedir. Ön yüzden çekilmiş temiz görüntülerin yanı sıra bu zorlukları barındıran birçok veriseti bulunmaktadır.

FDDB[79] (Face Detection Dataset and Benchmark): 2845 görüntü ile toplamda 5171 yüz görüntüsü içermektedir. Gri tonlama ve renkli görüntülerin olduğu veri setinde, tıkanıklık, kapanmalar, zor pozlar ve düşük çözünürlüklü görüntüler bulunmaktadır.

LFW[80] (Labeled Faces in-the-Wild): 13.233 görüntü, 5749 yüz görüntüsü içermektedir. 1680 görüntü iki veya daha fazla yüz içermektedir. Yüz bulma yöntemlerinin doğruluğunu ölçmede yaygınca kullanılan verisetinin tek kısıtı viola- jones bulucusu tarafından tespit edilebilmesidir.



a) fddb



b) lfw



c) aflw



d) lfpw



e) casiaWebface



f) muct



g) helen

Şekil 3.2. Yüz bulma veri setlerinden alınmış görüntü örnekleri

AFW[81] (Annotated Faces in-the-Wild): Zhuo ve ark. tarafından oluşturulmuş veri seti, 250 görüntü ile 468 yüz içermektedir. Her yüz için altı yüz işareti sağlanmaktadır.

AFLW (The Annotated Faces Landmark in-the-wild): Flickr'den indirilmiş 25.993 görüntü ile 24.686 yüz içermektedir. Geniş aralıkta doğal pozlar bulunmaktadır. Yüz işareti açıklamaları tüm veriseti için mevcuttur. 21 yüz işaret noktasından oluşmaktadır.

MUCT[82]: 3755 görüntü ile 276 kişi ihtiva eden veri seti, 76 işarete sahiptir. Görüntüler, aydınlanma, yaş, ırk gibi farklılıkları barındırmaktadır.

FERET[83] (The Facial Recognition Technology Database): 256x 384 boyutlu 807 görüntüden meydana gelmektedir.

LFPW[84] (Labeled Face Parts in-the-wild) : Google, flickr ve yahoo'dan indirilmiş 1.287 görüntü ihtiva etmektedir. Veriseti, geniş çeşitlilikte poz, aydınlanma ve tıkanma etkisinin olduğu görüntülerden meydana gelmektedir.

HELEN[85]: Flickr' den indirilmiş 2330 açıklamalı görüntüden oluşmaktadır. Bazen 500x500'den daha büyük yüz boyutları bulunmaktadır. Sağlanan açıklamalar çok detaylı olup 194 yüz işareti vardır.

Tablo 3.1. Yüz bulma problemi için sıklıkla kullanılan uluslararası kabul görmüş veri setleri

Veri seti	Görüntü Sayısı	Yüz işaret sayısı	Boyut	Renk
FDDB	2845 görüntü 5171 yüz	-	-	Gri tonlama/Renkli
LFW	13.233 görüntü 468 yüz	-	-	Renkli
AFW	250 görüntü 468 yüz	6	-	Renkli
AFLW	25.933 görüntü	21	-	Renkli/gri tonlama
LFPW	1287 görüntü	35	-	Renkli
HELEN	2.330 görüntü	194	500x500 ⁺	Renkli/gri tonlama
MUCT	3755 görüntü 276 yüz	76	480x640	Renkli
FERET	807 görüntü	-	256x384	Renkli


Önerilen yöntemin eğitimi için, AFLW veri seti kullanılmıştır. 25.933 tane görüntü ihtiva eden veri seti bu kadar örnekle çok doğru sonuçlar vermez. Pozitif (yüz) veri sayısını arttırmak amacıyla IoT metriğini kullanarak kayan pencereler ile pozitif ve negatif veriler olmak üzere iki alt veri seti elde ettik. IoT oranı % 50'den büyük ise alt pencereyi yüz olarak kabul ettik.

Veri setini oluştururken 25.933 görüntünün hepsini kullanmadık. Eğitim örneği sayısı arttıkça sistem doğruluk oranı artıyor olsa da eğitim sürecinin artacak olması ve kullandığımız makinenin oluşacak milyonlarca görüntüyü işleyebilecek yeterliliği olmamasından dolayı sayı fazla arttırılmamıştır. Yapılan işlem sonrası pozitif örnek sayısı, 56.798 ve negatif örnek sayısı 243.470 olarak ayarlanarak, negatif/ pozitif oranı 1/4 civarında tutulmuştur.

3.2. CNN Mimarisi

Evrişimsel sinir ağı mimarileri birkaç katmandan oluşabileceği gibi [73]'da olduğu gibi çok derin de olabilmektedir. Kullanılacak olan mimariye deneme yanılma yoluyla veya adaptif [86] yöntemler yardımıyla karar verilmektedir. Kullanılan mimaride katman sayısının az olması genelde problemin çözümünde başarı sağlayamaz. Diğer yandan katman sayısının çok fazla olması, parametre sayısını arttıracığından zaman verimliliğini düşürmektedir. Dolayısıyla mimarinin uygun katman sayısı içermesi yöntemin başarısı açısından önem arz etmektedir.

Ağ mimarisinde katman sayısı önemli olduğu gibi, kullanılan katmanların özellikleri, filtrelerin boyutu ve sayısı, aktivasyon fonksiyonu, öğrenme parametreleri gibi birçok değer de önemlidir. Krizhevsky ve ark. 2012'deki imageNet yarışmasında ilk olarak kullandıkları Alexnet mimarisi, görüntü sınıflandırmada büyük başarı sağlamıştır. Şekil 3.3. AlexNet, evrişimsel sinir ağı mimarisini vermektedir.



Şekil 3.3. Alexnet, evrişimsel sinir ağı mimarisi

Krishevsky'nin AlexNet'i, 11 katmandan meydana gelmektedir. İlk iki katmanı evrişim+max+norm, üç ve dördüncü katmanlar evrişim, beşinci katman evrişim+max, altı ve yedinci katmanlar tam bağlantılı ve son katman sınıflandırma işlemi yapan softmaxdir.

1.Katman: Evrişim katmanı

- Filtre sayısı: 96
- Filtre boyutu: 11x11
- Stride (adım): 4
- Padding (şişirme):0
- Görüntü boyutu: $(227-11)/4+1 = 55$ 'den 55x55x96

2.Katman: Maksimum havuzlama katmanı

- Filtre sayısı: 96
- Filtre boyutu: 3x3
- Stride (adım): 2
- Görüntü boyutu: $(55-3)/2+1 = 27$ 'den 27x27x96

3.Katman: Evrişim katmanı

- Filtre sayısı: 256
- Filtre boyutu: 5x5
- Stride (adım): 1
- Padding (şişirme):2
- Görüntü boyutu: 27x27x256

4.Katman: Maksimum havuzlama katmanı

- Filtre sayısı: 256
- Filtre boyutu: 3x3
- Stride (adım): 2
- Görüntü boyutu: $(27-3)/2+1 = 13$ 'den 13x13x256

5.Katman: Evrişim katmanı

- Filtre sayısı: 384
- Filtre boyutu: 3x3
- Stride (adım): 1
- Padding (şişirme):1
- Görüntü boyutu: 13x13x384

6.Katman: Evrişim katmanı

- Filtre sayısı: 384
- Filtre boyutu: 3x3
- Stride (adım): 1
- Padding (şişirme):1
- Görüntü boyutu: 13x13x384

7.Katman: Evrişim katmanı

- Filtre sayısı: 256
- Filtre boyutu: 3x3
- Stride (adım): 1
- Padding (şişirme):1

- Görüntü boyutu: 13x13x256

8.Katman: Maksimum havuzlama katmanı

- Filtre sayısı: 256
- Filtre boyutu: 3x3
- Stride (adım): 2
- Görüntü boyutu: $(13-3)/2+1=6$ 'dan 6x6x256

9.Katman: Tam bağlı katman

- Nöron sayısı: 4096
- $6 \times 6 \times 256 = 9216$ piksel 4096 nöronun her biri ile beslenir.

10.Katman: Tam bağlı katman

- 9. Katman ile aynıdır.

11.Katman: Tam bağlı katman

- Nöron sayısı: 1000
- Sınıflandırmanın olduğu katmandır. 1000 görüntü için sınıflandırma yapıldığı için son katmanda 1000 tane nöronun her biri bir sınıfı temsil etmektedir.

Evrişimsel sinir ağları mimarisindeki katmanların özellikleri ve nasıl işlev yaptıkları hakkında ayrıntılı bilgi bölüm 2.3.2' de verilmektedir.

3.3. Eğitim

Problemin çözümünde uygulamanın belki de en önemli ve oldukça uzun süren safhası eğitimidir. Eğitim işlemi, kullanılan modelin parametre sayısı ve veri boyutuna bağlı olarak günlerce sürebilmektedir. Yüz bulma işlemini gerçekleştirmek için, negatif ve pozitif görüntülerin kullanılacak olan modele öğretilmesi gerekmektedir. Uygulamamızda, Alexnet benzeri bir model ile caffe açık kaynak yazılımından yararlanılarak eğitim safhası gerçekleştirilmiştir.

3.3.1. Alexneti İnce Ayarlama (Finetuning)

İnce ayar, önceden öğrenilmiş bir modeli alır, mimari uyarlar ve eğitimin hâlihazırda öğrenilen model ağırlıklarından devam etmesini sağlar. Eğitim için kullandığımız AFLW veri kümesi Flickr kaynaklı görüntülerdir ve görsel olarak bvlc_reference_caffenet'in eğitildiği ImageNet veri kümesine çok benzemektedir. Bu model nesne kategorisi sınıflandırması için iyi çalıştığından, bu mimariyi yüz ayırt etme için kullanmaktayız. Imagenet, 1 milyon görüntü ihtiva etmektedir. Çok sayıdaki bu görüntülerin üzerinde öğrenilen parametrelerle bağlamak ve gerektiğinde ince ayar yapmak istemekteyiz.

Tablo 3.2. Alexnet, ile ince ayar sonrası kullanılan model

İnce Ayar İşleminde sonra AlexNet	Katman
Giriş (227x227)	0
evrişim (55x55)	conv1
Maksimum havuzlama (27x27)	Pool1
Evrişim(27x27)	Conv2
Maksimum havuzlama (13x13)	Pool2
Evrişim(13x13)	Conv3
Evrişim(13x13)	Conv4
Evrişim (13x13)	Conv5
Maksimum havuzlama (6x6)	Pool5
Tam Bağlı (9216- 4096)	Fc6
Tam Bağlı (4096- 4096)	Fc7
Tam Bağlı (4096- 2)	Fc8-Flickr

Ağırlık argümanını, caffe [87], eğitim komutuna verirse, önceden eğitilmiş ağırlıklar modelimize yüklenir ve katmanları ona göre eşleştirir. AlexNet ile ince ayarlama yaparken, modelimizde değiştirmemiz gereken yerler bulunmaktadır. ImageNet bulunan görüntüleri 1000 kategoriye göre sınıflama görevi yapmaktadır fakat biz yüz veya yüz değil ikili sınıflandırma yapılmasını istiyoruz. Dolayısıyla, modeldeki son katman olan sınıflama katmanını değiştirmemiz gerekmektedir. Ayrıca prototxt dosyasında fc8 isimli katmanı, fc8_flickr olarak değiştiririz. Bvlc_reference_caffenet modelinde bu isimde katman bulunmadığından, bu katman rastgele ağırlıklar ile eğitime başlayacaktır. Tablo 3.1. AlexNet ile ince ayarlanmış modeli vermektedir.


3.3.2. CAFFE derin öğrenme kütüphanesi

Theano, Lasagne, Keras, mxnet, Torch ve TensorFlow gibi konvolüsyonel sinir ağları da dahil olmak üzere sinir ağlarının tasarımı ve öğretilmesi için kullanılabilen çeşitli güçlü kütüphaneler vardır. Bunların arasında Caffe, hem gerçek dünya uygulamaları araştırmak hem de geliştirmek için kullanılabilecek bir kütüphanedir.

Caffe, derin mimarilere açık erişim imkânı tanıyan, tamamen açık kaynaklı bir kütüphanedir. Kod, GPU hesaplaması için kullanılan CUDA, Python / Numpy ve MATLAB için neredeyse eksiksiz, iyi desteklenmiş bağlamalarla, verimli C ++ ile yazılmıştır. Caffe, yazılım mühendisliği en iyi uygulamalarına bağlı olarak doğruluk, deneysel titizlik ve kurulum hızı için birim testleri sunmaktadır. Ayrıca, kodun dikkatli modülerliği ve ağ tanımının gerçek uygulamadan temiz bir şekilde ayrılması nedeniyle araştırma kullanımı için de uygundur.

Caffe, hızlı ve standart stokastik eğim iniş (Stochastic Gradient descent) [88] algoritması ile modelleri eğitmektedir. Önerilen yöntemde, optimizasyon stokastik eğim iniş tarafından 64' lük mini yığınlar kullanılarak ve 0.9 momentum katsayısı ile sağlanmaktadır. Model, “dropout” ve “weight decay” kullanılarak düzenlenmektedir.

Eğitim sırasında: Bir veri katmanı, görüntüleri ve etiketleri diskten alır, evrişim, havuzlama ve düzeltilmiş doğrusal dönüşümler gibi birden çok katman üzerinden geçirir ve son tahmini yapar. Veriler, ağdan sırayla geçen minik yığınlar halinde işlenir. Eğitim için hayati olan şey, öğrenme hızı azalma zaman çizelgeleri, momentum ile durma ve devam ettirme için anlık görüntülerdir; bunların tamamı uygulanmakta ve belgelendirilmektedir [87]. Önerilen yöntemin öğrenme eğrisi şekil 3.4.'deki gibidir.



Şekil 3.4. Sistemin öğrenme eğrisi

3.4. Test ve sonuçlar

Önerilen yöntemin, uzun süren eğitim süreci sonunda, istenilen işlemi yapıp yapmayacağını kontrol etmek için erişime açık veri setleri olan FDDB, MUCT veri setleri ve Google. com'dan indirilen görüntüler ile test edilmiştir. Bölüm 3.1'de verilmekte olduğu gibi, test için kullanılan MUCT, aydınlanma, yaş, ırk, cinsiyet gibi farklılıklar barındırmaktadır. Bütün görüntülerde tek bir kişi bulunmaktadır. FDDB ise tıkanıklık, kapanmalar, zor pozlar ve düşük çözünürlüklü görüntüler içermektedir. Veri setinde, sadece bir kişinin olduğu görüntüler olmasının yanı sıra çoklu görüntüler de bulunmaktadır.




Şekil 3.5. Fddb veri setinden alınmış görüntülerde çoklu yüz bulma



Şekil 3.6. Fddb veri setinden alınmış farklı etnik yapıdaki kişilere ait görüntülerde yüz bulma



Şekil 3.7. FDDB veri setinden alınmış tek bir yüz içeren görüntülerde yüz bulma



Şekil 3.8. Google.com'dan alınmış birden fazla yüz içeren görüntülerde yüz bulma



Şekil 3.9. MUCT veri setinden alınmış görüntülerde yüz bulma

Şekil 3.5, 3.6, 3.7, 3.8 ve 3.9’da farklı görüntüler kullanılarak yapılmış testler sonucu bulunan yüzler verilmektedir. Yöntem, aydınlanma, tıkanıklık ve poz değişikliği zorluklarının olmadığı şekil 3.8’deki gibi görüntülerde (100 görüntü için test yapılmıştır) % 97 civarında bir doğru bulma sağlamaktadır.

FDDB veri seti kullanılarak yapılmış test sonuçları, şekil 3.5, 3.6 ve 3.7’de verilmektedir. Yöntem, görüntüdeki yüzleri büyük oranda doğru bulmaktadır. FDDB veri setindeki 300 görüntü ile test gerçekleştirilmiştir. Yöntem, 255 görüntüdeki bütün yüzleri bulmuş, diğer görüntülerde bulamadığı yüzler olmuştur. Dolayısıyla % 85 civarında bir başarımla göstermektedir diyebiliriz.

Şekil 3.9’da MUCT veri seti kullanılarak yapılmış test sonuçları verilmektedir. Veri setindeki 500 veri kullanılarak yöntemin doğruluğu kontrol edilmiştir. Bu görüntülerden 440 tanesinde doğru bulma sağlanmış, 60 tanesinde ise sınırlayıcı kutu yüzün olduğu yeri yanlış göstermiştir. Yöntem, MUCT veri seti ile yapılan doğruluk testinden % 84 civarında bir oranla çıkmıştır.

Yapılan deneyler önerilen yöntemin kabul edilebilir sonuçlar üretebildiğini göstermektedir. Zorlu görüntülerde yeteri kadar doğru bulma sağlayamayan yöntemin geliştirilmesi gerekmektedir.

4. EVRİŞİMSEL SİNİR AĞI TABANLI YÜZ TANIMA YAKLAŞIMI


Tezin bu bölümünde evrişimsel sinir ağı kullanan bir derin yüz tanıma yöntemi sunulmaktadır. İnsan beyni daha önce den kim olduğunu biliyorsa, bir kişiyi rahatlıkla tanıyabilmektedir. Fakat bilgisayar söz konusu olduğunda, bu işlem biraz zorlayıcı olmaktadır. İnsan beyni, bir kişiyi göz rengi, saç şekli, burun yapısı gibi özelliklerine bakarak tanıyabilmektedir. Bu özellikleri, kişiyi yüz bilgisine bakarak tanımasını istediğimiz, görüntüye piksel piksel bakarak işlem yapan bilgisayara öğretmek pek yerinde bir davranış olmayacaktır. Bilgisayara elle yapılmış özellikler öğretilerek işlemi yapması sağlanabilmektedir. Öte yandan yapılan araştırmalar bilgisayarın kendiliğinden öğrendiği özelliklerin tanımada daha etkili olduğunu göstermektedir. Evrişimsel sinir ağları özellik çıkartma görevinde oldukça başarılıdır. CNN'nin çıkardığı özellikler, kenar bilgisi gibi basit özellikler olduğu gibi göz gibi karmaşık özellikler de olabilmektedir.

Önerilen yöntemde dlib[89] ve torch [90] kütüphaneleri ile openface [91] ön eğitilmiş modelleri ile uygulama gerçekleştirilmektedir. Yüz tanıma işlemine kadar olan adımlarda çeşitli görevler için, HOG algoritması, yüz işaret tahmini (facial landmark estimation) algoritması ile CNN ve SVM kullanılmaktadır.

4.1.Önerilen Yöntemin Edinme Yolu

Yüz tanıma algoritmalarının edinme yolu, kayıt aşaması ve tanıma aşaması olmak üzere iki kısımdan oluşmaktadır. Şekil 4.1 yüz tanıma yöntemlerinin aşamalarını vermektedir.

Kayıt aşamasında, sistem milyonlarca görüntü ile eğitilir ve eğitilmiş bir model elde edilir. Üretilen yüz özellikleri, veri tabanında depolanır. Tanıma aşamasında, sisteme bir sorgu yüzü verilir ve gerekli adımlardan sonra kayıt aşamasında oluşturulmuş olan kayıtlı özellik veri tabanı ile karşılaştırılarak tanıma işlemi yapılır. Kayıt aşaması için oldukça fazla görüntü kullanarak eğitilmiş ön eğitilmiş modeller bulunmaktadır. Önerilen yöntemde, bir python ve torch uygulaması olan Openface, açık kaynak yazılımının ön eğitilmiş modellerinden yararlanılmaktadır. Yöntemin edinme yolu ayrıntılı olarak bu bölümde anlatılmaktadır.



Şekil 4.1. Yüz tanıma yöntemlerinin edinme yolu

4.1.1. Yüz Bulma

Yüz tanıma algoritmalarının ilk adımı yüz bulmadır. Literatürdeki çalışmaları verdiğimiz bölüm 2'ye bakarak, yüz bulma problemi için birçok yöntemin geliştirilmiş ve hala geliştirilmekte olduğunu söyleyebiliriz. Bu yöntemlerden Viola- Jones, 2000'li yılların başında eski çözümlere nazaran yeterince iyi çözümler getirir. Fakat yıllar ilerlerken, bilim ve teknoloji de aynı oranda ilerlemektedir.

Geçmişten günümüze gelene kadar geliştirilmiş video ve fotoğrafta çalışan birçok yöntem, viola ve jones'un geliştirdiği algoritmadan daha uygun çözümler üretmektedir. Bunlardan birisi olan HOG (Histogram of Oriented Gradient)'u önerilen yöntemimizde yüz bulma adımı için kullanmaktayız.


HOG özellik tanımlayıcısında yönlendirilmiş gradyanların dağılımı özellikler olarak kullanılır. Bir görüntünün eğimleri(gradyan) ve türevleri (x,y) yararlıdır. Çünkü gradyanların büyüklüğü kenarlar ve köşeler çevresinde büyüktür. Ayrıca kenarlar ve köşeler düz alanlara kıyasla nesnenin şekli hakkında daha fazla bilgi vermektedir.

Yoğun örtüşen ızgaralı olan HOG özellikleri, kişi algılaması için çok iyi sonuçlar verir. HOG özellikleri, iyi performans için önemli olan hassas yönlendirme bölmesi, ince ölçek

gradyan, nispeten kat uzaysal bölme ve yüksek kaliteli yerel kontrast normalizasyonu avantajına sahiptir [92].

▪ Görüntülerin Gradyanını Hesaplama



Bir HOG tanımlayıcı hesaplamak için, önce yatay ve düşey eğimleri hesaplamamız gerekir. Sonuç olarak degradelerin histogramını hesaplamak istiyoruz. Bu işlemi yatay ve dikey $-1,0,1$ filtresi veya sobel ile görüntüyü filtreleyerek elde edebiliriz.



Şekil 4.2. (a) Google.com'dan alınmış görüntü **(b)** yatay degrade maskeli yüz imajı **(c)** yatay ve dikey degradelerin birleşimi ile oluşmuş yüz imajı **(d)** dikey degrade maskeli yüz imajı

Şekil 4.2(a)'da google'dan aldığımız, hiçbir işlemten geçirilmemiş bebek yüzü verilmektedir. Şekil 4.2(b)'de görüntü yatay iniş filtresinden geçirildikten sonra dikey (y) noktaları kendini gösterirken şekil 4.2(d)'de dikey iniş filtresiyle işlem gören imajda, yatay (y) noktaları keskinleşmiştir. Şekil 4.2 (c), her iki maske ile maskelenmiş olup x ve y noktalarında değişimin olduğu yerlerin hepsi belirginleşmiştir. Bölge pürüzsüz olduğunda, eğim değişimi olmayacağından hiçbir bölge belirginleşmez. Görüntümüz bebek yüzü olduğundan fazla ayrıntı içermemektedir.

İndirgeme işlemi, görüntüdeki çok önemli olmayan bilgileri kaldırır. Sadece görüntünün hala anlaşılmasını sağlayan ana hatlar kalır. Şekil 4.2 (b), 4.2 (c) ve 4.2 (d)'de maskelenerek indirgeme işleminden geçirilen görüntülere bakıldığında hala bir yüz olduğu görülebilmektedir.



Şekil 4.3. Görüntünün odaklı eğimlerinin histogramı

Eğim hesabından sonra, eğimlerin histogramı hücre hücre hesaplanır ve normalize edilir. Şekil 4.3'de görüntünün odaklı eğimlerinin histogramı verilmektedir. Bir görüntü yamasının HOG tanımlayıcısı hücre başına piksel sayısı 16x16 olarak hesaplanmıştır. Şekil 4.4'de HOG algoritması kullanılarak bulunan yüzler verilmektedir.



Şekil 4.4. HOG kullanarak LFW veri setindeki görüntülerde yüz bulma

4.1.2. Önışleme


Önerilen yöntemin ilk adımı sonrası bulunan yüzler, gürültü, aydınlanma, poz değişikliği gibi tanımayı önleyici faktörler içerebilmektedir. Bu durumda, görüntülerin iyileştirilmesi gerekmektedir. Evrişimsel ağlarda, kullanılan filtre sayısı ve özellikleri için bir sınır bulunmamaktadır. Gürültü ve aydınlanma zorlukları uygun herhangi bir filtre yardımıyla giderilmesi doğru yüz tanıma için elzemdir.



Şekil 4.5. LFW veri setindeki görüntülerde yüz işaret tahmini

Yüz görüntülerinin döndürülmesi, afin dönüşümü kullanılarak gerçekleştirilebilir. Bu işlem için, afin dönüşümü dışında birçok yöntem bulunmaktadır. Önerilen yöntemde, yüzsel özellik tahminine dayalı 68 özellik analizi algoritması kullanılmaktadır. Her yüzde 68 dönüm noktası belirlenmektedir [93]. Bu noktalar, her gözün dış kenarı, burun ve dudakların şeklini alan noktalar gibi özel bilgilerdir.

Şekil 4.5 LFW veri setinden alınan görüntülerde yüz işaret tahminini gösterirken, şekil 4.6. 68 yüz işaret algoritması kullanılarak, görüntünün hizalanmasını gösteren imajları vermektedir.



Şekil 4.6. Ön işleme sonrası hizalanmış görüntü

4.1.3. Özellik Çıkartma


Yüzler bulunduktan sonra önışlem safhasında çeşitli filtreler ile görüntüdeki gürültü ve aydınlanma etkisi azaltılmış, yüz özellik tahmini ile de görüntü hizalanmıştır. Artık görüntüler görevi yerine getirmek üzere, özellik çıkartılmak için eğitilebilir. Özellik çıkartma aşaması, yüz tanıma operasyonunda önemli bir adımdır. Eğer bu basamak yeterince iyi performans göstermezse, en iyi sınıflandırıcılar bile uygun sonuç üretemez.

Doğal imgeler, sabit olma özelliğine sahiptir; yani, görüntünün bir bölümünün istatistikleri herhangi diğer bir bölümle aynıdır. Bu, görüntünün bir bölümüne öğrendiğimiz özelliklerin aynı zamanda resmin diğer bölümlerine de uygulanabileceğini ve aynı özellikleri tüm konumlarda kullanabileceğimizi göstermektedir. Amaç, kişi içi farklılıkları en aza indirgeyen, diğer yandan kişiler arası farklılıkları en üst düzeye çıkartan temsiller bulmaktır.

Özellik çıkarımı, resimdeki fazlalığı ve ilgisizliği azaltmak için dijital görüntülere çıkarma algoritması uygulamasıdır. Öznitelik çıkarımının ana hedefleri, bir boyut azaltılması için makine eğitimi süresini ve alanın karmaşıklığını azaltmaktır [94].

Özellik çıkartma algoritmaları, girdi verilerini özellik setine dönüştürür, bu arada orijinal veriden en alakalı bilgileri içeren özellikleri seçer. Özellik özütleme, alakasız özelliklerin maksimum sayısını azaltarak kabul edilebilir sınıflandırma doğruluğunu sürdürür. Yüz özelliklerini çıkarmak için iki ortak yaklaşım vardır: Geometrik özellikler ve Görünüşe dayalı yöntemler [95]. PCA, LDA, DCT ve haar özellikleri insan yüzünü temsil eden bazı özelliklerdir. Bununla birlikte, en iyi yaklaşım bilgisayarın insan yüzlerini en iyi tanımlayan görüntülerden ölçümlerini öğrenmesine ve bulmasına izin vermektir.


Derin öğrenme, bir yüzün hangi kısmının ölçümünün tanıma için önemli olduğunu tanımlayabilmektedir. CNN, önemli özellikleri öğrenmek için eğitilebilir. Evrimsel ağı eğitmenin birçok yöntemi bulunmaktadır. Her bir yüz için 128 ölçüm türetmek üzere bir CNN eğiten yöntem araştırmacılarca sunulmaktadır [96]. Çeşitli gömme boyutları araştırılarak sonuçlar karşılaştırılmış ve en iyi sonuçları verdiği için 128 seçilmiştir. Eğitim sırasında 128 boyutlu şamandıralı bir vektör kullanılır, ancak doğruluk kaybı olmaksızın 128 bayt'a nicelendirilebilir. Böylece her yüz 128 boyutlu bir bayt vektörüyle kompakt olarak temsil edilir, bu da büyük ölçekli kümeleme ve tanıma için idealdir. Daha küçük gömülmeler hafif bir doğruluk kaybıyla mümkündür ve mobil cihazlarda kullanılabilir [96].



Şekil 4.7. Ön işleminden geçirilmiş görüntüden 128 ölçüm eldesi

Şekil 4.7 ön işleminden geçirilmiş görüntüden özellik çıkarma işlemini vermektedir. Evrişimsel sinir ağının eğitimi üç adımda gerçekleştirilmektedir. Bilinen bir kişinin yüzü eğitilir. Aynı kişinin farklı bir görüntüsü verilir. Ardından tamamen farklı bir kişiye ait bir görüntü verilir. Algoritma, şu anda bu üç veya daha fazla görüntünün her biri için üretmekte olduğu ölçümlere bakar. Ağ ilk iki görüntü için üretilen ölçümlerin, diğer görüntü için üretilen ölçümlerden farklı olduğundan emin olacak şekilde ayarlanmıştır. Ağ bu işlemi milyonlarca kez, binlerce farklı kişiye ait görüntü için yaptığında artık her bir kişi için 128 ölçüm üretebilir. Eğitim süreci yüz özellik vektörünü çıkıtlamak için zaman almaktadır. Aynı zamanda çok fazla bilgisayar gücü gerektirmektedir. Şekil 4.8 ölçümü üretilen eğitim görüntülerinden birinin ölçümlerini vermektedir.

Eğitim, veri seti boyutuna bağlı olarak bir günden fazla sürebilmektedir. Fakat ağ eğitildikten sonra, daha önce görmediği görüntüler için bile özellik üretebilmektedir. Bir kişinin farklı açılardan çekilmiş görüntülerinin ölçümleri neredeyse aynı çıkmaktadır. Önerilen yöntemde önceden eğitilmiş openface modelini kullanıyoruz ve yüz görüntülerimizi ağdan geçirerek ölçümleri elde ediyoruz.




Şekil 4.8. Eğitim verisinden çıkartılan yüz özelliklerine ait ölçümler

4.1.4. Yüz Tanıma

Yüz tanımanın son adımıdır. Sorgu yüzümüz için en yakın özellik vektörü, bilinen kişiler veri setinden en yakın kimse onu bulur. Bu aşamada herhangi bir sınıflandırma algoritması tercih edilebilir. Sınıflandırma işlemi için kullanılacak birçok algoritma bulunmaktadır. Bayes sınıflandırıcı, SVM, Öklid uzunluğu, K-means bunlardan bazılarıdır.

Destek vektör makinaları sınıflandırma işlemlerinde oldukça başarılıdır. Son yıllarda görüntü işleme problemlerinin çözümünde hibrit sistemler yaygın şekilde kullanılmaktadır. Hibrit sistemler, çoğunlukla başarılı olduğu için sınıflandırma aşamasında destek vektör makinalarını kullanmaktadırlar [97,98]. Doğru bulmayı en iyi şekilde sağlaması için önerilen yöntem de de SVM tercih edilmektedir. Şekil 4.9 SVM çalışma mantığını vermektedir.



Şekil 4.9. SVM ile Çoklu sınıflarda sınıflandırma işlemi


4.2. Test ve Sonuçlar

Önerilen yöntem, yüz tanıma işleminde istenilen sonuca gidilen yolda birçok teknoloji yardımıyla neticelendirilmektedir. İlk olarak tanıma işleminin yapılması istenen görüntüde yüz ayırt etme işlemi yapılmaktadır. Bu işlem yapılırken, HOG algoritmasından faydalanılmaktadır.

İkinci aşama aydınlanma etkisi, poz değişikliği ve gürültü ihtiva eden görüntüler için elzem olan ön işleme adımdır. Ön işleme adımı, filtreler yardımıyla gürültü ve aydınlanma giderilmekte iken poz değişiklikleri için yüz işareti tahmin algoritması kullanılarak hizalama yapılmaktadır. Sonraki kısım, görüntü işleme problemlerinin en önemli adımı olan özellik çıkartma adımdır. Eğer özellikler iyi çıkartılmazsa, bu özelliklere göre sınıflandırma yapılacağından çok iyi bir sınıflandırıcı bile işlemin doğruluğunu artırmaya yetmeyecektir.

Evrişimsel sinir ağları kullanılarak, sorgulanan hizalanmış görüntüden 128 ölçüm çıkartılmaktadır. Bu ölçümler benzer görüntülerde birbirine çok yakın olmaktadır. Son adım olan yüzü tanıma safhasında çıkartılan 128 ölçüme bakılarak en yakın sınıfa dâhil etmek suretiyle yüz tanıma işlemi sonuçlandırılmaktadır. Bunun için son yıllarda hibrit

sistemlerin çoğunun sınıflandırma safhasında kullanılan destek vektör makinaları tercih edilmektedir. Şekil 4.10 önerilen yöntemin bir özetini vermektedir.



Şekil 4.10. Önerilen yöntemin işlem şeması

Sistemi test etmek amacıyla, üç sınıf belirlenerek her bir sınıfa 5 adet görüntü konulmuştur. Obama, Trump ve Biden sınıfına ait görüntüler şekil 4.11'de

göstermektedir. Eğitim verisi arttıkça doğruluk oranının artacağı muhakkaktır fakat sistemin sağlamlığını görmemiz açısından bu kadar görüntü de fena değildir.



(a)



(b)



(c)

Şekil 4.11. Kullandığımız örnek 3 sınıfa ait eğitim görüntüleri, (a) Obama (b) Trump ve (c) Biden sınıfına ait görüntüler

Test için her sınıfa ait 4 görüntü ve hiçbir sınıfa ait olmayan bir adet görüntü kullanılmıştır. Bütün görüntüler doğru sınıfa dâhil edilmiştir. Kendisine ait görüntülerin eğitime sokulmayıp tanıtılmadığı bebek görüntüsü ise az bir uyum ile Biden sınıfına daha yakın görülmüştür. Kullandığımız az sayıdaki veriye rağmen yöntem doğru sonuçlar elde etmektedir. Şekil 4.12. bazı test verilerini ve tahmin edilen sınıfı göstermektedir.

Sorgulanan Görüntü	Sınıf Tahmini
--------------------	---------------

	0.78 uyum ile Obama Sınıfı
	0.65 uyum ile Trump sınıfı
	0.62 uyum ile Biden sınıfı
	0.39 uyum ile Biden

Şekil 4.12. Sorgu yüzlerine ait test sonuçları

5.SONUÇ

Bu tez çalışmasında son yıllarda akademi camiasında dikkat çeken çözümler sunan ve görüntü işleme 'den doğal dil işlemeye birçok makine öğrenme probleminde kullanımı artarak devam eden, derin öğrenme yaklaşımından bahsedilmiştir. Derin öğrenme yaklaşımının yapısı, özellikleri ve en çok tercih edilen mimarileri verilmiştir. Görüntü işleme problemlerinde, özellikle özellik çıkartma safhasında son teknoloji başarı elde eden evrimsel sinir ağları mimarisine ayrıntılı olarak yer verilerek katmanlarının özellikleri ve çalışma yapısı özetlenmiştir.

Literatürdeki yüz ayırt etme ve tanıma problemlerinin çözümü için geliştirilmiş mevcut çalışmalar incelenmiştir. Mevcut çalışmalarda, yüz bulma algoritmalarında yaygın olarak kullanılan şablon eşleme, görünüm tabanlı, özellik değişmez tabanlı ve bilgi tabanlı yaklaşımlara ait bazı çalışmalar irdelenerek eksik yönleri görülmüştür.

Literatürde verilen çalışmalar incelendiğinde, evrimsel sinir ağları kullanılarak geliştirilen yöntemlerin yüksek başarı oranı gösterdiği görülmektedir. Önden çekilmiş görüntü ve poz değişikliğinin bulunmadığı görüntülerde yöntemlerin büyük çoğunluğu kabul edilebilir sonuçlar elde etmektedir. Zor yüzlerin bulunduğu veri setleri ile işlem yapıldığında ise doğruluk oranları büyük oranda düşmektedir. Tez kapsamında evrimsel sinir ağı tabanlı bir yüz bulma yaklaşımı önerilmiştir.

Tez çalışmasında yüz bulmanın yanı sıra, yüz tanıma işlemi melez bir yaklaşımla elde edilmiştir. Mevcut çalışmalara bakıldığında, yüz tanımanın ilk adımı olan yüz bulma işlemini olumsuz etkileyen faktörler, aynı oranda yüz tanıma işlemini de etkilemektedir. Derin öğrenme mevcut problemlerin doğruluk performanslarını büyük oranda arttırmış olsa da mükemmel değildir. Doğru tanımanın yapılabilmesi için yöntemlerin hala geliştirilmesi gerekmektedir.

KAYNAKLAR

- [1] **Varol, A., Cebe, B.,** Yüz Tanıma Algoritmaları, 5 th International Computer & Instructional Technologies Symposium., Firat University, ELAZIĞ-TURKEY.
- [2] **Chen, W., Wang, K., Jiang, H., Li, M.,** Skin color modeling for face detection and segmentation: a review and a new approach, *Multimedya Tools and Applications*, 75(2), 839-862, 2016.
- [3] **Ghimire D., Lee, J.,** A Robust Face Detection Method Based On Skin Color And Edges, *J Inf Process Syst*, Vol.9, No.1, March, 2013..
- [4] **Jairath, S., Bharadvaj, S., Vatsa, M., Singh, R.,** Adaptive Skin Color Model to Improve Video Face Detection, , *Machine Intelligence ang Signal Processing*, Springer India, p. 131-142, 2016.
- [5] **Lan, O., Xu, Z.,** Adaboost multi-view face detection based on YCgCr Skin Color model, *Eight International Symposium on Advanced Optical Manufacturing and Testing Technology (AOMATT2016)*, p. 96842D-96842D-5-528, 2016.
- [6] **Kang, S., Byuoungio C., Donghw, J.,**Faces Detection Method Based on Skin Color Modeling, *Journal of Systems Architecture*, 64, 100-109, 2016.
- [7] **Zhou, S., Yin, J.,** Face detection using multi-block local gradient patterns and support vector machine, *Journal of Computational Information Systems*, 2014, 10(4), 1767-1776.
- [8] **Jinxin, R., Yin J.,** Face detection based on facial features and linear support vector machines, *Communication Software and Networks, ICCSN'09 International Conference on IEEE*, 2009.
- [9] **Zhang, X, Pu, J., Huang X.,** Face Detection Based on Two Dimensional Principal Component Analysis and Support Vector Machine, *Mechatronics and Automation Proceedings of the 2006 IEEE International Conference on IEEE*, 1488-1492, 2006.
- [10] **El-Bakry, Hazem, M., Hamada, M.,** Fast Principal Component Analysis for Face Detection using Cross-correlation and Image Decomposition, *Neural Networks, IJCNN 2009*, 751-756, 2009.
- [11] **Li Y.Y., Tsai C.C., Chen Y.Z.,** Face Detection, Identification and Tracking using Support Vector Machine and Fuzzy Kalman Filter , *Machine Learning and Cybernetics (ICMLC)*, 2011.

- [12] **Yang H.C, Xu A.W.**, Cascade Face Detection Based on Histograms of Gradients and Support Vector Machine, Parallel, Grid, Cloud and Internet Computing (3PGCIC), 2015 10th International Conference on IEEE, 2015.
- [13] **Viola, P., Jones M.J.**, Robust real face detection, International Journal of Computer Vision, 57(2), 137-154, 2004.
- [14] **Coster, J., Ohlsson, M.**, Human Attention: The possibility of measuring human attention using OpenCV and the Viola-Jones face detection algorithm, 2015.
- [15] **Irgens, P., Bader, C., Lé, T., Saxena, D., Ababei, C.** An efficient and cost effective FPGA based implementation of the Viola-Jones face detection algorithm, *HardwareX*, vol.1 p. 68-75, 2017.
- [16] **Zhao, X., Chai, X., Niu, Z., Heng, C., & Shan, S.**, Context modeling for facial landmark detection based on Non-Adjacent Rectangle (NAR) Haar-like feature, *Image and Vision Computing*, 30(3), 136-146, 2012.
- [17] **Aziz, K.A.A., Shahrum, S.A.**, Face Detection Using Radial Basis Functions Neural Networks With Fixed Spread, *arXiv preprint arXiv:1410.2173* , 2014.
- [18] **Ali, N. M., Karis, M. S., Aziz, M. A., Abidin, A. F. Z.**, Analysis of frontal face detection performance by using Artificial Neural Network (ANN) and Speed-Up Robust Features (SURF) technique, M. H. R. O. Abdullah, Y. H. Min, N. A. M. Bashar, & S. M. F. S. A. Nasir (Eds.), *AIP Conference Proceedings* , Vol. 1774, No. 1, p. 050013, AIP Publishing, 2016
- [19] **Joseph, S., Sowmiya, R., Thomas, R. A., Sofia, X.** Face detection through neural network. In *Current Trends in Engineering and Technology (ICCTET)*, 2014 2nd International Conference, p. 163-166. IEEE, 2014.
- [20] **Bulo, S. R.**, Face detection with neural networks, *Universita Ca'Foscari Venezia DAIS*, 2012.
- [21] **Zhonghua, C., Lichuan, H., Tiejun, W., Fengyi, G.**, Modeling Study of the Amount of Wear in Sliding Electric Contact, 26th International Conference on Electrical Contacts (ICEC 2012), 146 – 150, 2012.
- [22] **Miry, A. H.**, Face Detection Based on Multi Facial Feature using Fuzzy Logic. *Al-Mansour Journal*, 21, 2014.
- [23] **Elbouz, M., Alfalou, A., & Brosseau, C.**, Fuzzy logic and optical correlation-based face recognition method for patient monitoring application in home video surveillance, *Optical Engineering*, 50(6), 067003-067003, 2011.
- [24] **Yang, S., Luo, P., Loy, C. C., Tang, X.**, From facial parts responses to face detection: A deep learning approach, In *Proceedings of the IEEE International Conference on Computer Vision* , p. 3676-3684, 2015.

- [25] **Qin, H., Yan, J., Li, X., Hu, X.,** Joint training of cascaded CNN for face detection, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, p. 3456-3465, 2016.
- [26] **Yadhul, K., Lakshmi, P. S., Saju, A.,** Face detection and recognition with video database, In *Electronics and Communication Systems (ICECS)*, 2014 International Conference on IEEE, pp. 1-5, 2014.
- [27] **Kong, K. H., Kang, D. S.,** A Study of Face Detection Using CNN and Cascade Based on Symmetry-LGP & Uniform-LGP and the Skin Color, 2016.
- [28] **Sun, X., Wu, P., Hoi, S. C.,** Face detection using deep learning: An improved faster rcnn approach. *arXiv preprint arXiv:1701.08289*, 2017.
- [29] **Zhang, K., Zhang, Z., Li, Z., Qiao, Y.** Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks, *IEEE Signal Processing Letters*, 23(10), 1499-1503, 2016.
- [30] **Sharma, S., Shanmugasundaram, K., Ramasamy, S. K.,** FAREC—CNN based efficient face recognition technique using Dlib. In *Advanced Communication Control and Computing Technologies (ICACCCT)*, 2016 International Conference on (pp. 192-195). IEEE, 2016.
- [31] **Zhao, W., Chellappa, R., Krishnaswamy, A.** Discriminant analysis of principal components for face recognition. In *Automatic Face and Gesture Recognition*, 1998. *Proceedings. Third IEEE International Conference on* (pp. 336-341). IEEE.
- [32] **Schroff, F., Kalenichenko, D., & Philbin, J.** Facenet: A unified embedding for face recognition and clustering. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 815-823, 2015.
- [33] **Zhou, E., Cao, Z., Yin, Q.,** Naive-deep face recognition: Touching the limit of lfw benchmark or not?, *ArXiv preprint arXiv*, 1501, 2011.
- [34] **Sun, Y., Liang, D., Wang, X., Tang, X.,** Deepid3: Face recognition with very deep neural networks, *arXiv preprint arXiv:1502.00873*, 2015.
- [35] **Simonyan, K., Zisserman, A.,** Very deep convolutional networks for large-scale image recognition. Technical report, *arXiv:1409.1556*, 2014.
- [36] **Szegedy C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.,** Going deeper with convolutions, Technical report, *arXiv:1409.4842*, 2014.
- [37] **Ahonen, T., Hadid, A., Pietikainen, M.,** Face description with local binary patterns: Application to face recognition, *IEEE transactions on pattern analysis and machine intelligence*, 28(12), 2037-2041, 2006.

- [38] **Lu, J., Tan, Y. P., Wang, G.,** Discriminative multimanifold analysis for face recognition from a single training sample per person, *IEEE transactions on pattern analysis and machine intelligence*, vol.35 no.1, 39-51, 2013.
- [39] **Dellana, R., Roy, K.,** Performance of feature-based texture classifiers versus Convolutional Neural Network under sparse training data. In *SoutheastCon*, 2017 (pp. 1-2). IEEE, 2017.
- [40] **Guo, S., Chen, S., Li, Y.,** Face recognition based on convolutional neural network and support vector machine, In *Information and Automation (ICIA)*, 2016 IEEE International Conference on, pp. 1787-1792, 2016.
- [41] **Parkhi, O. M., Vedaldi, A., Zisserman, A.,** Deep Face Recognition, In *BMVC*, Vol. 1, No. 3, p. 6, 2015.
- [42] **Khalajzadeh, H., Mansouri, M., Teshnehlal, M.,** Face recognition using convolutional neural network and simple logistic classifier. In *Soft Computing in Industrial Applications*, Springer International Publishing, pp. 197-207. 2014.
- [43] **Fei, Z., Qiang, Q.,** Face detection based on rectangular knowledge rule and face structure. In *Information Science and Engineering (ICISE)*, 2009 1st International Conference on (pp. 1235-1239). IEEE.
- [44] **Devadethan, S., Titus, G., Purushothaman, S.,** Face detection and facial feature extraction based on a fusion of knowledge based method and morphological image processing, In *Emerging Research Areas: Magnetics, Machines and Drives (AICERA/iCMMD)*, 2014 Annual International Conference on (pp. 1-5). IEEE, 2014.
- [45] **Holat, R.,** Yüz bulma ve tanıma sistemleri kullanarak kimlik tespiti nin yapılması, Yüksek Lisans Tezi, Elektrik Elektronik Mühendisliği Bölümü, Düzce Üniversitesi, 2014.
- [46] **Yang, M. H., Kriegman, D. J., Ahuja, N.,** Detecting faces in images: A survey, *IEEE Transactions on pattern analysis and machine intelligence*, vol.24, no.1, 34-58, 2002.
- [47] **Chao, W. L.,** Face Recognition, GICE, National Taiwan University, 2007.
- [48] **Sudha, N., Mohan, A. R.,** Hardware directed fast eigenface based face detection algorithm using FFT. In *Industrial Electronics*, 2009. ISIE 2009. IEEE International Symposium on (pp. 915-919). IEEE.
- [49] **Mohan, A. R., Sudha, N.,** Fast face detection using boosted eigenfaces. In *Industrial Electronics & Applications*, 2009. ISIEA 2009. IEEE Symposium on (Vol. 2, pp. 1002-1006). IEEE.

- [50] **Saber, E., Tekalp, A. M.,** Frontal-view face detection and facial feature extraction using color, shape and symmetry based cost functions, *Pattern Recognition Letters*, vol. 17, no. 8, pp. 669-680, 1998.
- [51] **Wei, Z., Dong, Y., Zhao, F., Bai, H.,** Face detection based on multi-scale enhanced local texture feature sets. In *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference*, pp. 953-956, 2012.
- [52] **Verma, K., Ukey, A.,** Face Detection Using Neural Network.
- [53] **Kalavdekar, P. N.,** Face Detection using Neural Network. *International Journal of Computer Applications*, pp. 0975–8887, vol.1, no.14, 2010.
- [54] **Bileschi, S. M., Heisele, B.,** Advances in component based face detection. In *Analysis and Modeling of Faces and Gestures, 2003. AMFG 2003. IEEE International Workshop on IEEE*, pp. 149-156, 2003.
- [55] **Pham, T. V., Worring, M., Smeulders, A. W.** (2002). Face detection by aggregated Bayesian network classifiers. *Pattern Recognition Letters*, vol.23, no.4, 451-461.
- [56] **Liu, X., Cheng, T.,** Video-based face recognition using adaptive hidden markov models. In *Computer Vision and Pattern Recognition, 2003. Proceedings. 2003 IEEE Computer Society Conference on IEEE*, Vol. 1, pp. I-I, 2003.
- [57] **Uddin, M. Z., Hassan, M. M.,** A depth video-based facial expression recognition system using radon transform, generalized discriminant analysis, and hidden Markov model, *Multimedia Tools and Applications*, , vol.74, no.11, pp. 3675-3690, 2015.
- [58] **Pakira, R.,** Face Detection using Template Maching, Doctoral dissertation, 2012.
- [59] **Tripathi, S., Sharma, V., Sharma, S.,** Face detection using combined skin color detector and template matching method. *International Journal of Computer Applications*, vol. 26 no. 7, pp. 5-8, 2011.
- [60] **Jafri, R., Arabnia, H. R.,** A survey of face recognition techniques. *Jips*, vol. 5 no. 2, pp. 41-68, 2009.
- [61] **R. Cendrillon and B. C. Lowell,** Real-Time Face Recognition using Eigenfaces, *Proceedings of the SPIE International Conference on Visual Communications and Image Processing*, Vol.4067, pp. 269-276, 2000.
- [62] **Kumar, K. S., Semwal, V. B., Tripathi, R. C.,** Real time face recognition using adaboost improved fast PCA algorithm. *arXiv preprint arXiv:1108.1353*, 2011.

- [63] **Panagakis, Y., Nicolaou, M. A., Zafeiriou, S., Pantic, M.,** Robust correlated and individual component analysis. *IEEE transactions on pattern analysis and machine intelligence*, 38(8), 1665-1678, 2016.
- [64] **Gonzalez, C. I., Melin, P., Castro, J. R., Mendoza, O., Castillo, O.,** General Type-2 Fuzzy Edge Detection in the Preprocessing of a Face Recognition System. *Nature-Inspired Design of Hybrid Intelligent Systems*, Springer International Publishing, pp. 3-18, , 2017.
- [65] **Lu, L., Hu, X., Chen, S., Sun, L., Li, C.,** Face recognition based on weighted wavelet transform and compressed sensing, In *Wireless Communications & Signal Processing (WCSP)*, 2016 8th International Conference on IEEE, pp. 1-5, 2016.
- [66] **Poon, B. S. L.,** Recognition of human faces in distorted images based on principal component analysis and gabor wavelets, 2016.
- [67] **Rahman, S. Z. A., Abdullah, S. N. H. S., Hao, L. E., Abdulameer, M. H., Zamani, N. A., & Darus, M. Z. A.,** Mapping 2D to 3D forensic facial recognition via bio-inspired active appearance model, *Jurnal Teknologi*, 78(2-2), 121-129, 2016.
- [68] **Neeru, N., & Kaur, L.,** Modified SIFT Descriptors for Face Recognition under Different Emotions. *Journal of Engineering*, 2016.
- [69] **Özcan, H.,** Çok Düşük Çözünürlüklü Yüz İmgelerinde Derin Öğrenme Uygulamaları, Yüksek Lisans Tezi, Deniz Harp Okulu, Bilgisayar Müh. Bölümü, 2014.
- [70] **Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle,** Greedy layer-wise training of deep networks, *Advances in Neural Information Processing Systems*, vol. 19, Cambridge, MA, USA:MIT Press, pp. 153, 2007.
- [71] **Açarçiçek, A. H.,** 2015, Derinlikli Öğrenme ile Konuşmacı Duygu Durumunun Sınıflandırılması, Lisans Tezi, İstanbul Teknik Üniversitesi, Elektronik ve Haberleşme Müh. Bölümü.
- [72] **Eral, M.,** Deep Learning Approasch for Laboratory mice grimace Scaling, Yüksek Lisans Tezi ODTÜ, Ankara, 2016.
- [73] **Krizhevsky, A., Sutskever, I. and Hinton, G. E.,** ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, 2012.
- [74] **Karpathy, A.,** Convolutional Neural Networks (CNNs / ConvNets). Retrieved August 7, 2016, from CS231n Convolutional Neural Networks for Visual Recognition:
- [75] **Liu, T., Fang, S., Zhao, Y., Wang, P., Zhang, J.,** Implemantation of training Convolutional Neural Networks, arXiv:1506.01195, Jun. 2015.

- [76] **Karaathl, M. A.**, Yapay Sinir Ağları Yöntemi İle Tahmin, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, İşletme Bölümü.
- [77] **Nair, V., Hinton, G. E.** Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th international conference on machine learning (ICML-10), pp. 807-814, 2010.
- [78] **Köstinger, M., Wohlhart, P., Roth, P. M., Bischof, H.**, Annotated facial landmarks in the wild: A large-scale, real-world database for facial landmark localization. In Computer Vision Workshops (ICCV Workshops), 2011 IEEE International Conference, pp. 2144-2151, 2011, November.
- [79] **Jain V, Learned-Miller EG.**, Fddb: A benchmark for face detection in unconstrained settings, UMass Amherst Technical Report, 2010.
- [80] **Huang, G. B., Ramesh, M., Berg, T., Learned-Miller, E.** 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, 2007.
- [81] **Zhu, X., Ramanan, D.**, Face detection, pose estimation, and landmark localization in the wild. In Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on (pp. 2879-2886). IEEE. (2012, June).
- [82] **Milborrow, S., Morkel, J., Nicolls, F.** The MUCT landmarked face database, Pattern Recognition Association of South Africa, 201(0), 2010.
- [83] **Phillips, P. J., Moon, H., Rauss, P. J., Rizvi, S.**, The FERET evaluation methodology for face recognition algorithms, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, No. 10, October 2000.
- [84] **Belhumeur, P. N., Jacobs, D. W., Kriegman, D. J., Kumar, N.**, Localizing parts of faces using a consensus of exemplars. IEEE transactions on pattern analysis and machine intelligence, 35(12), 2930-2940, 2013.
- [85] **Le, V., Brandt, J., Lin, Z., Bourdev, L., Huang, T.**, Interactive facial feature localization. Computer Vision–ECCV 2012, 679-692, 2012.
- [86] **Zhang, Y., Zhao, D., Sun, J., Zou, G., & Li, W.**, Adaptive convolutional neural network and its application in face recognition. Neural Processing Letters, 43(2), 389-399, 2016.
- [87] **Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... Darrell, T.**, Caffe: Convolutional architecture for fast feature embedding. In Proceedings of the 22nd ACM international conference on Multimedia (pp. 675-678). ACM. 2014, November.

- [88] **Tang, S.**, Stochastic gradient descent, 2017.
- [89] **King, D. E.**, Dlib-ml: A machine learning toolkit. *Journal of Machine Learning Research*, 10:Jul: 1755-1758, 2009.
- [90] **Collobert, R., Bengio, S., Mariéthoz, J.**, Torch: a modular machine learning software library (No. EPFL-REPORT-82802), Idiap, 2002.
- [91] **Schroff, F., Kalenichenko, D., Philbin, J.**, Facenet: A unified embedding for face recognition and clustering. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 815-823), 2015.
- [92] **Dadi, H. S., Pillutla, G. K. M.**, Improved Face Recognition Rate Using HOG Features and SVM Classifier.
- [93] **Kazemi, V., Sullivan, J.**, One millisecond face alignment with an ensemble of regression trees. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1867-1874), 2014.
- [94] **Khokher, R., Singh, R. C., Kumar, R.** Footprint Recognition with Principal Component Analysis and Independent Component Analysis. In *Macromolecular Symposia*, Vol. 347, No. 1, pp. 16-26. DOI: 10.1002/masy.201400045, 2015.
- [95] **Mahto, S., Yadav, Y.**, A Survey on Various Facial Expression Recognition Techniques, *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, Vol. 3, No. 11. pp. 13028- 13031, 2014.
- [96] **Schroff, F., Kalenichenko, D., Philbin, J.**, Facenet: A unified embedding for face recognition and clustering. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 815-823, 2015.
- [97] **Tao, Q. Q., Zhan, S., Li, X. H., Kurihara, T.**, Robust face detection using local CNN and SVM based on kernel combination. *Neurocomputing*, 211, 98-105. 2016.
- [98] **Zhan, S., Tao, Q. Q., Li, X. H.**, Face detection using representation learning. *Neurocomputing*, 2016, 187: 19-26.

ÖZGEÇMİŞ

Emine CENGİL 1991 yılında Elazığ’ da doğdu. İlk, orta ve lise öğrenimini Elazığ’ın Baskil ilçesinde tamamladı. 2009 yılında Baskil Lisesini birincilikle bitirdikten sonra 2014 yılında Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümünden mezun oldu. 2015 yılında Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim dalında yüksek lisans yapma hakkı kazandı. 2016 yılında Bitlis Eren Üniversitesi, Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Ana Bilim dalında Araştırma görevlisi olarak atandıktan sonra 35. Madde görevlendirmesi ile Fırat Üniversitesinde aynı ana bilim dalında çalışmaya başladı. Halen Fırat Üniversitesi, Mühendislik Fakültesi Bilgisayar Mühendisliğinde görev yapmaktadır.