T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI

GABOR DALGACIK DÖNÜŞÜMÜNE DAYALI EVRİŞİMLİ SİNİR AĞLARINI KULLANARAK İNSAN YÜZÜ TANIMA SİSTEMİ

Salimah Ali Salim ALMARAGHI

YÜKSEK LİSANS TEZİ

Dr. Öğr. Üyesi Ümit TÖKEŞER

OCAK - 2022
KASTAMONU

TEZ ONAYI

Salimah ALMARAGHİ tarafından hazırlanan "**Gabor Dalgacık Dönüşümüne Dayalı Evrişimli Sinir Ağlarını Kullanarak İnsan Yüzü Tanıma Sistemi**" adlı tez çalışmasının savunma sınavı **15.10.2021** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği / oy çokluğu ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman	Dr. Öğr. Üyesi Ümit Tökeşer Kastamonu Üniversitesi	.....
Jüri Üyesi	Ünvan Ad SOYAD XXX Üniversitesi	.....
Jüri Üyesi	Ünvan Ad SOYAD XXX Üniversitesi	.....

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü Prof. Dr. İzzet ŞENER .....

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Salimah Ali Salim ALMARAGHI

ÖZET

YÜKSEK LİSANS TEZİ

GABOR DALGACIK DÖNÜŞÜMÜNE DAYALI EVRİŞİMLİ SİNİR AĞLARINI KULLANARAK İNSAN YÜZÜ TANIMA SİSTEMİ

Salimah Ali Salim ALMARAGHI

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: Dr. Öğr. Üyesi Ümit TÖKEŞER

Yüz tanıma için Derin Öğrenme Yönteminin kullanılması, tanımada daha büyük doğruluğu sağlar. Derin öğrenme, yüz tanıma sistemine implante edilen Gabor dalgacık dönüşümüne dayanır. Bu tezde yüz tanıma için yeni bir yaklaşım olan Gabor Dalgacık Dönüşümüne dayalı derin öğrenme yöntemi sunulmuş ve Farklı amaçlar için kullanılmak üzere geliştirilmiş yüz tanıma sistemi önerilmiştir. Yüz eğitim verilerinin özellik çıkarımı için Gabor Dalgacık Dönüşümünü (GDD) kullandık ve ardından bu özellikleri yüzlerin tanınması için Evrişimli sinir ağına kullandık. ORL veri tabanlarında önerilen yöntemi uyguladık ve değerlendirdik. Bu çalışma aynı zamanda tanıma sisteminde ön işleme aşamasının ne kadar önemli olduğunu da incelemektedir.

ANAHTAR KELİMELER: Yüz Tanıma, Gabor Dalgacık Dönüşümü, Derin Öğrenme, Python.

Ocak 2022, 52 Sayfa.

ABSTRACT

MSC THESIS

HUMAN FACE RECOGNİTİON SYSTEM WİTH CONVOLUTİONAL NEURAL NETWORK BASED ON GABOR WAVELET TRANSFORM

Salimah Ali Salim ALMARAGHI

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF MATERIALS SCIENCE AND ENGINEERING
SUPERVISOR: Assist. Prof. Dr. Ümit TÖKEŞER

Using Deep learning method for face recognition lead to better recognition accuracy. Deep learning based on Gabor wavelet transform implanted on face recognition system. In this thesis, deep learning method based on Gabor Wavelet Transform, which is new approach for face recognition, is presented. Proposed face recognition system developed to be used for different aims. We used Gabor Wavelet Transform (GWT) for feature extraction of face training data and then we used these features to Convolutional neural network for recognition of the faces. We implemented and evaluated the proposed method on ORL databases. This study also examines how importance of the preprocessing stage in recognition system.

KEYWORDS: Face Recognition, Gabor Wavelet Transform, Deep Learning, Python.

January 2022, 52 Page.

TEŞEKKÜR

İlk olarak, Dr. Ümit Tokeşer'e bu araştırma boyunca gözetmenlik yaptığı için teşekkür etmek isterim. Aynı zamanda, bu araştırmayla ilişkili pek çok pratik ihtiyaç hakkında yardımcı oldukları için Bilgisayar Mühendisliği Anabilim Dalı öğretim üyeleri ve araştırma görevlilerine teşekkürü borç bilirim. Destekleri için Kastamonu Üniversitesi ve Kastamonu'daki Libyalı topluluğundaki meslektaşlarıma teşekkür etmek isterim. Aynı zamanda, beni bu bursla ödüllendirdiği için sponsorum Libya Yükseköğretim Bakanlığı'na ve Ankara'daki Libya Büyükelçiliği'ne bağlı olan kültür işleri bölümüne bolca teşekkür ve minnet ediyorum.

Salimah Ali Salim ALMARAGHI

Kastamonu, 2022

İÇİNDEKİLER

Sayfa

TEZ ONAYI ..... **ii**
TAAHHÜTNAME ..... **iii**
ÖZET ..... **iv**
ABSTRACT ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİLLER DİZİNİ ..... **ix**
TABLOLAR DİZİNİ ..... **x**
SİMGELER VE KISALTMALAR DİZİNİ ..... **xi**
1. GİRİŞ **1**
1.2 Temel 3
1.2.1 Neden Yüz Tanıma? 3
1.3 Yüz Tanıma Tarihi 4
1.4 Yüz Tanıma 5
1.5 Gabor Dalgacık Dönüşümü (GDD) 6
1.6 GDD Neden Yüz Tanımada Kullanılıyor? 6
1.7 Yüz Tanımada GDD Uygulama 6
1.8 GDD'nin Avantajları 6
1.9 Sorun Bildirimi 7
2. LİTERATÜR İNCELEMESİ **8**
2.1 Temel 8
2.2 TBA ile Yüz Tanıma 11
2.3 Yüz Tanıma için Kullanılan Yöntemler 15
2.3.1 Bütünsel Yöntemler 15
2.3.2 Yerel Yöntemler 15
2.3.3 Hibrit Yöntemler 16
2.3.4 Temel Bileşen Analizi (TBA) 16
3. METODOLOJİ **17**
3.1 Derin Sinir Ağı 17
3.1.2 Aktivasyon Fonksiyonu 18
3.1.2.1 Sigmoid işlevi 18
3.1.2.2 Doğrultulmuş doğrusal birim (DDB) 19
3.1.2.3 Hiperbolik tanjant (tanh) 20
3.1.2.4 Softmax işlevi 20
3.1.3 Maliyet Fonksiyonu 21
3.1.3.1 Hatanın karesi toplamı (HKT) 21
3.1.3.2 Kategorik çapraz-entropi (KE) 22
3.1.4 İyileştiriciler 22
3.1.4.1 Gradyan inişi 23
3.1.4.2 Adagrad 25
3.1.4.3 Adadelta 25
3.1.4.4 Adam 26
3.1.4.5 Rmsprop 26
3.2 Model Mimarimiz 27

3.2.1.2 Evrişim katmanı 29
3.2.1.3 Havuzlama katmanı 31
3.2.1.4 Modelimizin mimarisi 32
4. DENEYSEL SONUÇLAR 34
4.1 Özellik Çıkarma Yöntemleri 34
4.1.1 Gabor Filtresi Kullanarak Özellik Çıkarma 34
4.2 ESA Kullanarak Algılama 37
4.3 Veri Tabanı 37
4.4 Önerilen Yöntemin Özeti 41
4.5 Kontrol Noktası Tekniğini Kullanma 42
5. SONUÇ 45
KAYNAKLAR 46
ÖZGEÇMİŞ 52

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1 Biyometrik siteme kayıt. 1
Şekil 1.2 Genel bir yüz tanıma çerçevesi. 2
Şekil 2.1 Yüz Tanıma için Bütünsel Yaklaşım 15
Şekil 2.2 Boyut Azaltma (sağ) ve Veri Sunumu (sol) için TBA 16
Şekil 3.1 Biyolojik nöron ve YSA 17
Şekil 3.2 Sigmoid. 19
Şekil 3.3 Doğrultulmuş doğrusal birim 19
Şekil 3.4 Hiperbolik tanjant (tanh). 20
Şekil 3.5 YSA Minarisi 28
Şekil 3.6 Filtreli tipik bir evrişim katmanı 29
Şekil 3.7 Bir yüz tanıma modelinde çeşitli evrişim katmanında özellik 31
Şekil 3.8 Maksimum havuz filtresi iş başında 32
Şekil 3.9 ESA Mimarisi 32
Şekil 4.1 Farklı dalga boyu değerleri (Sol: 25, Sağ: 50). 35
Şekil 4.2 Farklı yönelim (Sol: 0, Sağ: 45). 35
Şekil 4.3 Faz kaydırma değerlerinin değiştirilmesi (Sol: 180, Sağ: 90). 35
Şekil 4.4 En boy oranı çok büyük (solda) ve çok küçük (sağda). 36
Şekil 4.5 Farklı bant genişliği değerleri (Sol: büyük, Sağ: küçük). 36
Şekil 4.6 ESA'nın topolojisi. 37
Şekil 4.7 ORL veri tabanı 38
Şekil 4.8 Çeşitli ESA yürütmeleri için doğruluk ve dönem grafikleri. 40
Şekil 4.9 Önerilen yöntemin özeti. 41
Şekil 4.10 Kontrol noktası tekniği ile sonuç 43
Şekil 4.11 Kontrol noktası tekniği olmadan sonuç 43

TABLOLAR DİZİNİ

Sayfa

Tablo 4.1 Derin Sinir Ağı Sonuçları.....39
Tablo 4.2 Evrişimli Sinir Ağı Sonuçları.....39

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

TBA	**:** Temel Bileşen Analizi
DDA	**:** Doğrusal Diskriminant Analizi
TDA	**:** Tekil Değer Ayrışımı
YİÖ	**:** Yerel İkili Örüntü
AKD	**:** Ayrık Kosinüs Dönüşümü
GDEBM	**:** Gri Düzey Eş Bulgu Matrisi
YİM	**:** Yerel İkili Mesen

1. GİRİŞ

Bilgisayar ve bilgisayar tabanlı sistemlerin geliştirilmesinden sonra günlük yaşama olan talebe bağlı olarak kullanım alanları artırılmıştır. Bilgisayarlar günlük hayatımızı kolaylaştırır ve her geçen gün değiştirir. Bilgisayar tabanlı sistemler için önemli taleplerden biri, güvenlik sistemleri için yüz algılama ve tanımadır. Görüntü işleme ve görüntü sıkıştırma, bilgisayar tabanlı sistemlerin önemli konularıdır. Uygulamada yüz algılama ve tanıma başta güvenlik sistemleri olmak üzere birçok uygulama alanına sahiptir. Şekil 1.1, biyometrik sisteme kayıt ve doğrulama işlemini göstermektedir.

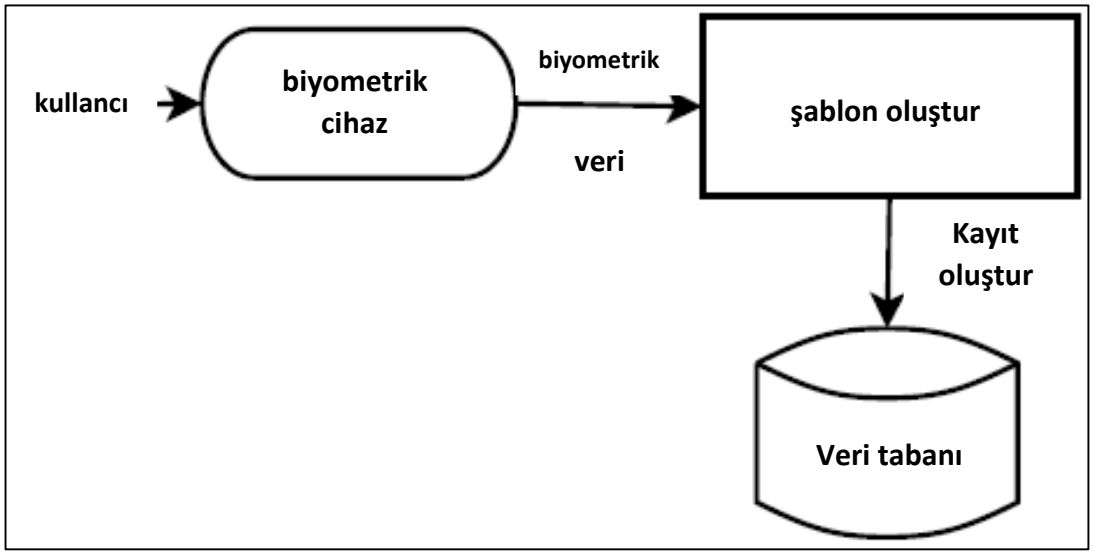

Şekil 1.1 Biyometrik siteme kayıt.

Şekil 1.1'de gösterildiği gibi, ilk önce biyometrik veriler yakalanır. Ardından, çıkarılan bilgiler bir kayıt şablonunda saklanır ve şablon veri tabanında depolanır. Genel bir yüz tanıma çerçevesi şekil 1.2'de gösterilmektedir.

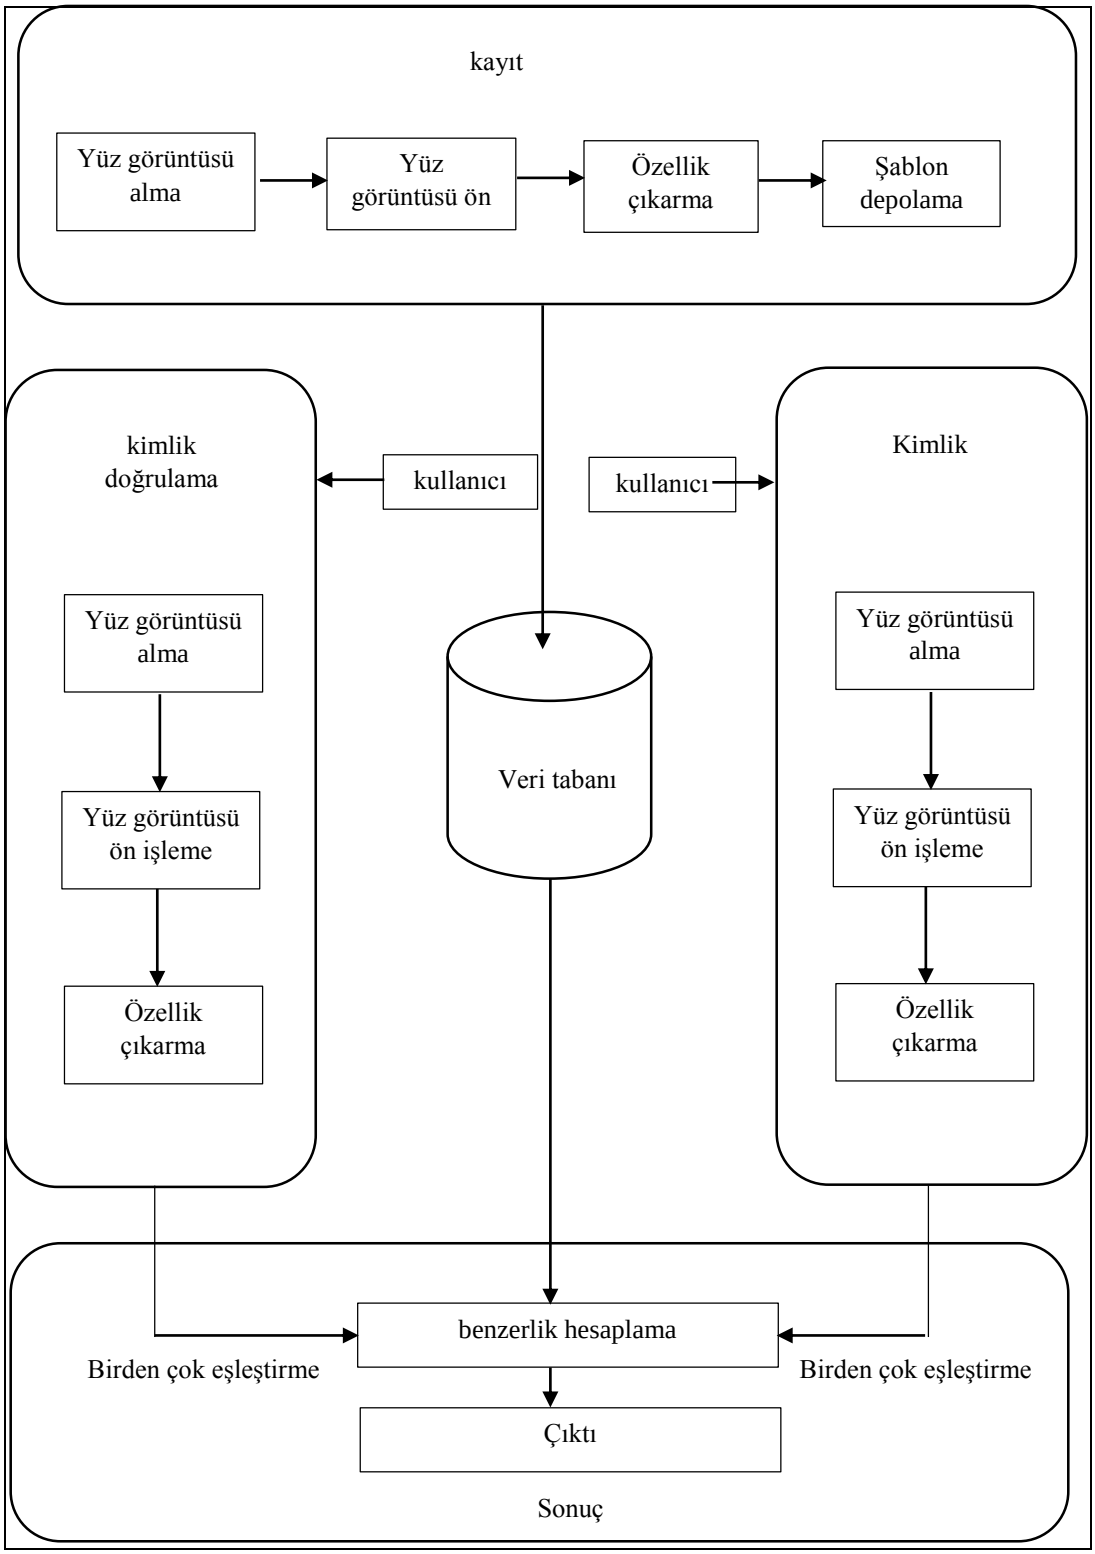

Şekil 1.2 Genel bir yüz tanıma çerçevesi.

Yüz tanıma, fizik, matematik, fizyoloji, biyoloji, bilgisayar bilimi diğerleri gibi çeşitli alanları kapsayan bir araştırma alanıdır. Bu çalışma, çeşitli düşündürücü uygulamaları gözden geçirerek ve özellikle Gabor Dalgacık Özelliklerine (GDÖ) odaklanarak

araştırma alanında etkinliğin ve verimliliğin nasıl geliştirilebileceğini analiz ederek yüz tanımadaki temel zorluklardan birini ele almaktadır. Eğitim ve test amaçlı ORL yüz veritabanı kullanılmıştır (Samaria ve Harter, 1994).

1.2 Temel

Woody Bledsoe, Helen Chan Wolf, ve Charles Bisson 1960'larda ilk yüz tanıma sistemini önerdiler (Bledsoe, 1966).

Fotoğraftaki yüz hatlarını bulmak için programlarda bir yöneticiye ihtiyaç vardı. Programlar, daha sonra bilinen verilerle eşitlenen belirli konum konumlarına göre uzunlukları ve oranları hesaplayarak yüzleri tanıdı. Yüz tanıma, yaşamdaki çok çeşitli aktivitelerde kullanılan daha geniş bir örüntü tanıma teknolojisi yelpazesinin bir alt kümesidir. Doğal durumlarda yüz tanıma, üç görsel görevin sağlam performansını gerektirir: edinme, normalleştirme ve tanıma. Edinme, yüz benzeri görüntü yamalarının dinamik bir sahnede tanındığı ve izlendiği süreci ifade eder. Normalleştirme, yüz görüntülerinin alt bölümlere ayrıldığı, yönlendirildiği ve normalleştirildiği süreçtir; tanıma ise, orijinal yüz görüntülerinin tanımlanmış reprodüksiyonlarla birlikte bireyseller olarak temsil edilip modellendiği süreçtir.

1.2.1 Neden Yüz Tanıma?

İnsanların kimliğinin doğrulanmasına yönelik artan ihtiyaç nedeniyle, ihtiyaç duyulan bilgiyi sağlamak için hangi teknolojinin en iyi şekilde yerleştirileceği sorusu vardır. Şu anda çeşitli tanımlama teknolojileri bulunmaktadır: Bu işlemlerin önemli bir kısmı yıllardır fiili olarak kullanılmaktadır. Kişisel Kimlik Numarası (PIN), kişisel kimliğin doğrulanması için en yaygın yöntemdir. Bununla birlikte, teknik çeşitli zorluklarla doludur: örneğin, bir kişinin PIN kodunu unutması veya yanlış girmesi muhtemeldir veya birisi onu çalabilir. Bu tür yükümlülüklere karşı koymanın etkili bir yolu, bireylerin belirli özelliklerini tanımak için örüntü tanıma tekniklerini kullanan biyometrik tanıma sistemlerinin kullanılmasıdır. Biyometrik tanımlama sistemlerinin örnekleri arasında parmak izleri, retina ve iris tanıma bulunur. Bununla birlikte, bu biyometrik tekniklerin bazılarının kullanılması kolay değildir, çünkü kullanıcının

sensöre göre kendisini konumlandırması ve tanımlama sürecinde biraz zaman ayırması gerekir, ancak birkaç modern yüz tanıma yöntemi özel konumlandırma gerektirmez.

Yüksek güvenlik önlemlerinde kimlik belirleme işlemi önemliyken mağaza gibi belirli ortamlarda uygun değildir. Video ve ses tanıma teknolojilerinin kullanımı, gelecek nesil akıllı ortamlarda yaygınlaşacak. Bu tanıma teknolojileri genellikle pasiftir, kullanıcının hareketlerini kısıtlamaz ve ekonomiktir. İnsanlar, yüz ve ses tanımayı içeren bir süreci kullanırken daha rahat olurlar çünkü birbirlerini sesleriyle ve yüzleriyle doğal olarak tanımlarlar.

1.3 Yüz Tanıma Tarihi

Yüz tanımanın pratik önemi ve bilişsel bilimlerin teorik ilgisi, araştırma alanını bilgisayar görüşü kadar köklü hale getirdi. Yüz tanıma, makinelerin karmaşık rolleri üstlenme ve insan yeteneklerini ve duyularını doldurma, düzeltme veya onlara yardım etme yeteneğinin artmasının sonucuydu. Makineler, yüz tanımanın yanı sıra tanıma amacıyla daha geniş bir kapsama sahiptir ve parmak izi veya iris taraması gibi araçları kullanabilir. Biyometrik tanımlama yöntemleri daha kesin olmakla birlikte, yüz tanıma, invaziv olmayan yapısı ve insanlar tarafından en çok tercih edilen kişi tanımlama yöntemi olması nedeniyle çeşitli araştırmalarla odak noktası olmuştur. Kişi tanımlama teknolojisinin başlangıcından bu yana araştırma alanlarında iki ana yöntem vardır: geometrik ve resimsel yaklaşım. Geometrik yaklaşım, kişinin yüzünün uzamsal taslağını kullanır. Bu yöntem, yüzün bölümleri arasındaki farklı geometrik uzunluklara ve eğimlere bağlı olarak bir kişinin görünümünü sınıflandırmadan önce öncelikle birincil geometrik yüz özelliklerini bulur. Resimsel yaklaşım, tersine, yüzün önden görünüşlerini tanımak için yüzün parçalarının şablonlarını kullanır. Her iki yaklaşımı da kullanan tekniklerin çoğu, farklı pozların arka planlarını ele alan uzantıları paylaşır. Geometrik ve resimsel yöntemlere ek olarak, görüntü gradyanına dayanan diğer şablon temelli yaklaşımlarla birlikte bir alt ideal model yöntemi olarak yorumlanabilecek birincil bileşen çalışma yöntemi vardır. Hem resimsel hem de geometri yöntemlerinin özelliklerini içeren ve değişen duruş veya ifadelerdeki yüzler için uygun deforme edilebilir model tekniği de vardır.

1.4 Yüz Tanıma

Yüz tanıma, giriş olarak dijital bir görüntü veya video kullanarak bir kişiyi tanımlama tekniğidir. Yüz tanıma sistemleri, aşamalı olarak başka birçok alanda kullanılmasına rağmen, öncelikle bir güvenlik önlemi olarak kullanılmaktadır. Çağdaş yüz tanıma yöntemleri yüz izlerini kullanır: bir kişinin yüzündeki 80 kadar düğüm özelliğini kategorize edebilen sayısal kodlar. Düğüm özellikleri, burnun boyutları, göz yuvalarının derinliği veya elmacık kemiklerinin çıkıntısı gibi yüzün değişkenlerini belirlemede yardımcı olan uç noktalar olarak hizmet eder. Sistemler, elde edilen bilgileri sayısal bir kod olarak kaydetmeden önce ilk olarak bir kişinin yüz görünümünün dijital bir modeli üzerindeki düğüm özelliklerini yakalar. Yüz tanıma sırasında yüz izi, bir görüntü veya video sekansında bulunan yüzlerden elde edilen bilgilerle değerlendirme amacıyla kullanılır.

Sayısal kodlar kullanan yüz tanıma ağları, koşullar uygun olduğunda ilgilenilen kişileri hızlı ve doğru bir şekilde tanıyabilir. Bununla birlikte, kısmen gizlenmiş bir yüz veya yetersiz aydınlatma gibi belirli koşullar veya yüzün öne doğru bakmak yerine profilde olması bile yazılımı daha az güvenilir hale getirebilir. 3D sensörler ve 3D özellik çıkarma gibi gelişmekte olan teknolojilerin yakında bu zorlukların üstesinden gelebileceği umulmaktadır.

Yüz tanıma teknolojisindeki gelişmelerin çoğu, yetenekleri sosyal ağ entegrasyon işlevleri için görüntü etiketlemeyi ve kişiselleştirilmiş pazarlamayı içeren akıllı telefon uygulamalarına odaklanmıştır. Örneğin, Carnegie Mellon Üniversitesi'ndeki bir araştırma ekibi, bir kişinin fotoğrafını çekebilen ve kişinin fotoğraflarına sosyal güvenlik numarası, tarihi ve adıyla birkaç saniye içinde eşlik edebilen bir iPhone uygulaması geliştirdi. Facebook şu anda bir kişinin yüz özellikleri hakkında bilgi depolamadan önce bir kişinin fotoğrafını otomatik olarak etiketleyen bir yüz tanıma sistemi kullanıyor. Yüz tanıma yazılımı, pazarlama kişiselleştirmesini geliştirmek için de kullanılıyor. Bir örnek, geçenlerin cinsiyetini, etnik kökenini ve yaklaşık yaşını belirleyebilen ve ardından reklamların içeriğini ayarlayabilen yazılıma entegre reklam panolarıdır (RASOOL, 2019).

1.5 Gabor Dalgacık Dönüşümü (GDD)

GDD, yüz tanıma, doku kategorizasyonu ve nesne algılama için görüntülerden özellik çıkarımı için kullanılan bir doku tanımlayıcısıdır.

1.6 GDD Neden Yüz Tanımada Kullanılıyor?

Yüz görüntüsü, daha sonra yüz tanımlayıcı olarak kullanılan gelişmiş bir özellik vektörü haline gelmek için her GDD doku özelliği dağılımını ayıklayıp birleştirmeden önce GDD kullanan yüz tanıma ağlarında bölgelere ayrılır. Bu tezde önerilen yöntem, yüz tanıma probleminin altında yatan farklı zorluklar açısından uygulanabilirlik açısından değerlendirilmiştir.

1.7 Yüz Tanımada GDD Uygulama

Yüz görüntülerinin temsilinde şekil ve doku ile ilgili bilgilerin dikkate alındığı yüz tanıma için yeni bir yöntem önerildi. İlk adım, yüz alanının daha küçük alanlara ayrılmasıdır, ardından GDD histogramları çıkarılır ve yüz görüntüsünü yetkin bir şekilde temsil eden uzamsal olarak güçlendirilmiş bir özellik histogramı oluşturmak için bağlanır. Yüz tanımlama, varyasyon ölçüsü olan figürlü özellik bölgesinde Derin Öğrenme Sinir Ağı sınıflandırıcısı kullanılarak gerçekleştirildi. Önerilen yöntem aynı zamanda basitliği nedeniyle hızlı öznitelik çıkarımına izin verir.

1.8 GDD'nin Avantajları

iii. Yüz tanımada diğer eşleştirme tekniklerine göre daha basit ve daha verimli.

iv. Düşük boyutlu alt uzay gösterimi, veri sıkıştırmaya izin verir.

v. Özümseme ve tanıma sırasında ham yoğunluk verilerinin düşük ila orta düzey sentezi.

vi. Yüzlerin geometrisi ve yansıması hakkında bilgi ihtiyacının olmaması.

1.9 Sorun Bildirimi

Geçen yüzyılda hem bilim adamlarının hem de mühendislerin dijital görüntülerden ve video karelerinden kişilerin kimliklerinin belirlenmesine ilgisinde artış olmuştur. Yüz tanıma sistemlerinin güvenlik sistemlerine, biyometrik sistemlere, ticari tanımlama ve pazarlama araçlarına entegre edilmesi bu yüzyıla kadar mümkün değildi. Yüz tanımanın bazı biyometrik teknikleri, deneklerin iş birliğini gerektirmemesi gibi kritik bir avantaja sahiptir. Günümüzde, kalabalığın içindeki kişileri sistemden haberdar etmeden tanımak için halka açık alanlara birçok yüz tanıma makinesi yerleştirilmiştir. Parmak izi taramaları, iris taramaları ve konuşma tanıma sistemleri gibi diğer biyometrik tanımlama sistemleri, deneğin onayını gerektirir. Bununla birlikte, bu yenilikler, kolluk kuvvetlerinin suçluları veri tabanlarına karşı çapraz kontrol etmelerine, tutuklamalarına ve cezai soruşturmaları etkili bir şekilde yürütmelerine yardımcı olmuştur. Facebook gibi birçok sosyal platform, kullanıcılar tarafından çekilen fotoğraflarda yüzleri bulunan kişileri etiketlemek için yüz tanıma tekniklerini uygulamaya başladı.

Yüz tanıma, artan güvenlik talebi ve mobil cihazların artması nedeniyle son zamanlarda popüler bir çalışma konusudur. Yüz tanıma sistemlerinin kullanışlılığı, kalabalık ve loş ışıklı yerlerde verimliliklerini artırmayı amaçlayan yeniliklere teşvik etti. Bu yeni özellikler yalnızca biyometrik sistemlere ve diğer ilgili endüstrilere değil, aynı zamanda sivil güvenliğin iyileştirilmesine de yardımcı olacaktır. Diğer uygulamalar arasında erişim kontrol sistemleri (ofislerde, bilgisayarlarda, telefonlarda, ATM'lerde vb.) kimlik doğrulama, güvenlik sistemleri, gösterim sistemleri ve sosyal medya ağları bulunur. Özetle, yüz tanıma, insanların kendilerini daha güvende hissetmek istediği ve aynı şeyi koruyabilen akıllı makinelerin bulunduğu toplumun hayati bir parçası haline geliyor. Bu nedenle, bu çalışma gibi yüz tanıma yöntemlerini ele alan araştırmalar önemlidir. GDD, literatürde yüz tanıma için kullanılan popüler bir yöntemdir. Bu çalışmanın problem bildirimi, ORL yüz veri tabanının kullanarak yüz tanıma problemi için Derin Öğrenme Sinir Ağı ve GDD algoritma performansını ölçmek ve sonuçları karşılaştırmaktır.

2. LİTERATÜR İNCELEMESİ

2.1 Temel

(Lu ve Zhang, 2016)'da yüz tanıma için ayrımcı sözlük öğrenimi ve seyrek temsil kullandılar. Yöntemlerinde, Gabor genlik görüntüleri Gabor filtre bankası tarafından uygulanmaktadır. Ayrıca yerel ikili model (YİM), özellik çıkarma için kullanılır. Yüz tanıma, görüntü işleme ve anlama alanındaki en popüler ve başarılı uygulamalardan biri olarak görülebilir (Zhao vd., 2003). Bununla birlikte, zorlu bir problem olarak, aydınlatma ve poz değişmez tanıma hala çık bir çalışma olarak kalmaktadır. Kontrolsüz bir ortamda çekilen yüz görüntüleri genellikle bakış açısı ve aydınlatma açısından farklılıklar içerir; bu nedenle, bu iki faktör sistemin sağlamlığında önemli bir role sahiptir. Elastik demet grafik eşleştirme (Wiskott vd., 1997) gibi özellik tabanlı yöntemlerin aydınlatma ve bakış açısı gibi birçok faktöre karşı ümit verici derecede başarılı olduğu uzun süredir bilinmektedir (Zhao vd., 2003). Bununla birlikte, özellik çıkarımına ve çıkarılan özelliklerin ölçülmesine olan aşırı duyarlılıkları onları güvenilmez kılar (Georghiades vd., 2001). Sonuç olarak, görünüm temelli yöntemler literatüre hakim olmuştur.

Yerel ikili örüntülerle (YİÖ) yüz tanıma, Ahonen ve diğerleri (Ahonen vd., 2004) tarafından önerilmiştir, çalışmalarında algoritma ışığa duyarlı değildir ve bu nokta çalışmalarının sağlamlığıdır.

Varyasyonlar altında yüz tanıma için kilometre taşlarından biri balıkçı yüzleri (Belhumeur vd., 1997) tekniği olarak ifade edilebilir. Doğrusal diskriminant analizi (DDA), (Belhumeur vd., 1997)'de, kişiler arası varyansın optimal olarak büyük ve kişi içi varyansın verimli bir şekilde küçük olduğu bir alt uzay oluşturmak için kullanılmıştır. TBA (Turk ve Pentland, 1991) ile aynı olan tekniğin ana dezavantajı, veri uzayının Öklid düşüncesidir. Veri noktaları doğrusal olmayan bir alt uzayda yer aldığında yöntem başarısız olur, bu genellikle çok modlu olarak dağıtılmış yüz görüntülerinde doğrudur.

Gabor özelliğine dayalı seyrek temsil algoritması Zhang ve diğerleri (Yang ve Zhang, 2010) tarafından önerilmiştir. Yöntemlerinde SRC ve Gabor özelliklerini birleştirip bu tekniği kullanarak insan yüzü tanıma oranını geliştirdiler ve hesaplamanın karmaşıklığını azalttılar.

(Kim ve Kittler, 2005)'de tek bir küresel dönüşüm yerine yerel doğrusal dönüşümlerin kullanılmasıyla umur verici bir gelişme önerildi. Yöntem, farklı poz sınıfları için farklı eşleşme işlevleri bulur. Bir prob görüntüsü test edildiğinde, pozu yumuşak bir kümeleme ile belirlenir. Poz kümelerinin sayısına karar vermek, tüm kümeleme algoritmalarında olduğu gibi hayati bir sorundur. Dahası, kritik varyasyonlarda yeni pozlar ele alınamaz. (He vd., 2005)'de yazarlar, çok modlu yüz görüntülerinin temelde yatan doğrusal olmayan manifoldunu belirlemek için girdi uzayının komşu yapısını kullandılar. Yerelliği Koruma Projeksiyonlar (YKP), laplas işleci yüzleri adı verilen bir temel seti hesaplamak için uygulandı. Farklı pozlar, yüz ifadeleri ve aydınlatma koşullarına sahip yüz görüntüleri incelendi ve tanıma performanslarının balıkçı yüzlerine veya öz yüzlere göre daha yüksek olduğu gösterildi. Poz varyasyonu (Pentland vd., 1994)'de görünüm tabanlı öz yüzler kullanılarak incelenmiştir. Her görünüm için, öz yüzler hesaplandı ve ortak bir alt boyutlu aly uzaya ayrı dönüşümler olarak kullanıldı. Yazarlar ayrıca öz nitelik tabanlı bir şemanın dahil edildiği öz nitelikleri tanıttılar. Performansları, (Gross vd., 2002)'da bir gerçek olduğu için büyük ölçüde ayrıklaştırmaya bağlıdır. (Gross vd., 2002)'de öz ışık alanları tekniği pozların alt uzayını tanımlamak için kullanılmıştır. Tanıdık olmayan pozlar teknikle ele alınabilir.

Kodlama katsayılarının bir sınıflandırıcısını eğiterek ayırt edici DL yöntemi Mairal ve diğerleri tarafından önerilmiştir (Mairal vd., 2009). Doku sınıflandırması ve rakam tanıma için yöntemlerini doğruladılar.

(Zhou ve Chellappa, 2004)'deki yazarlar, genelleştirilmiş fotometrik stereo ve öz ışık alanı konseptini, aydınlatma değişikliklerine karşı da duyarsız olan genel bir yöntem tasarlamak için birleştirdiler. (Georghiades vd., 2001; Blanz ve Vetter, 2003; Zhang ve Samaras, 2006; Zhang ve Samaras, 2006)'da yeni pozlar ve bunların performanslarını oluşturmak için boyutlu şekil değiştirebilen yüz modelleri

kullanmışlardır ve performans değerleri önceki araştırmalardan üstündü. Yeni pozlar ve aydınlatma koşulları için işleme yeteneği, 3D değiştirilebilir modellerle çok iyidir (Blanz vd., 2004). Ancak, 2D görüntülerden 3D modeller oluşturmanın veya 3D modellere erişmek için lazer tarayıcıları kullanmanın hesaplama maliyeti, tanıma sisteminin uygulanabilirliğini azaltır.

Aydınlanma varyansı (Shashua ve Riklin-Raviv, 2001)'de çalışılmıştır. Yazarlar bölüm görüntüsünü aydınlatmaya duyarsız kimlik imzası olarak önerdiler. Prob görüntüsünün öngörülemeyen bir gölgesi olduğunda yaklaşım başarısız olabilir; ancak galeri görüntülerinden farklı aydınlatmalı prob görüntülerini tanıma özelliğine sahiptir. Teknik, konu başına yalnızca bir galeri resmi gerektirir. (Zhou ve Chellappa, 2003)'teki yöntem, gölge kısıtlamasını ortadan kaldırmak için albedo ve normal yüzey üzerine ekstra kısıtlamalar getirdi. (Georghiades vd., 2001)'de bir aydınlatma konisi modeli önerilmiştir. Yazarlar, sabit bir pozdaki bir nesnenin görüntü kümesinin ancak tüm aydınlatma koşullarında dışbükey bir koniyi tanımladığını savundu. Yöntem, yüzey geometrisini ve albedo haritasını tahmin etmek için bir test kimliğinin birkaç görüntüsünü gerektirir. Poz varyasyonlarını ele almak için, örneklenen her bakış açısı için farklı aydınlatma konileri tanımladılar. Lambertian nesneler için her türlü aydınlatma koşulunu oluşturmak için kullanılabilecek tüm Lambert yansıtma fonksiyonları setleri (Basri ve Jacobs, 2003) ve (Ramamoorthi, 2002)'de tanımlanmıştır. Yalnızca dokuz küresel harmonik kullanarak geniş bir aydınlatma çeşitliliğinin tahmin edilebileceğini gösterdiler. Tanıma için bir metodoloji de (Basri ve Jacobs, 2003)'de önerilmiştir. (Zhang ve Samaras, 2006)'de küresel harmonik yaklaşımdan yararlanıldı ve tanınma için mükemmel sonuçlar temsil edildi. Poz değişmezliği elde etmek için 3D morphable modeli uyguladılar ve bu, 2L görüntülerden 3D yüz modelleri oluşturmayı gerektirir.

(Liu vd., 2016)'da, yüz tanıma için işbirlikçi temsil gerçekleştirmek için orijinal ve simetrik yüz eğitimi örnekleri kullandılar.

(Vasilescu ve Terzopoulos, 2003)'deki yazarlar, yüz ifadeleri, aydınlatma ve pozlar gibi farklı koşullarda yüzlerin tensör temsilini kullanan doğrusal olmayan bir alt uzay yaklaşımı önermişlerdir. Görüntü temeli oluşturmak için n mod tensör Tekil Değer

Ayrışımı (TDA) kullandılar. Yöntem, her eğitim kimliği için farklı varyasyonlar altında birkaç görüntü gerektirir. (Wang vd., 2008)'de, manifold varsayımı ile başka bir doğrusal olmayan alt uzay analizi önerildi. Her kimlik için, veri tabanında bir galeri manifoldu saklanır. Birkaç yeni pozu olan bir test kimliği geldiğinde, sonda manifoldu oluşturulur ve manifoldun mesafeyi katlamasıyla kimliği belirlenir. Deneğin birden fazla görüntüsünün gerekliliği ana dezavantajdır. (Tenenbaum ve Freeman, 2000)'deki ortogonal faktörleri ayrıştırmak için kullanılabilen bilineer üretici modeller tarafından önemli bir fikir ortaya atıldı. Yazarlar, giriş alanı ile alt boyutlu alt uzay arasında ayrılabilir bir çift doğrusal eşleştirme tanımladılar. Eşleşmelerin tüm parametreleri belirlendikten sonra, kimlik ayrılabilir ve açık bir şekilde bilgi sunulabilir. Tekniğin tanıma ve sentezleme yeteneklerini analiz ettiler ve sonuçlar umut vericiydi. (Shin vd., 2008)'de aydınlatma değişmezliği benzer bir çerçeve kullanılarak analiz edildi. Simetrik çift doğrusal modeldeki matris ters çevirme gereksiniminin üstesinden gelmek için, yazarlar bir sırt gerileme tekniği önerdiler. Poz varyasyonlarıyla başa çıkmak için (Prince vd., 2008)'de modifiye edilmiş bir asimetrik model tanıtıldı. Poz alanı için ayrıklaştırma çözümü, performansın önde gelen faktörlerinden biridir. Üretken modeller için doğrusal olmama, (Elgammal ve Lee, 2004)'ya dahil edilmiştir. Yazarlar, çift doğrusal modelle birlikte doğrusal olmayan bir şema önermişler ve klasik üretici modellerin doğrusallık kısıtı kaldırılmaya çalışılmıştır.

2.2 TBA ile Yüz Tanıma

Yüz tanıma ve TBA yöntemi ile ilgili birçok araştırma olmasına rağmen, TBA yöntemi kullanılarak yüz tanıma konusunda kısıtlı araştırmalar yapılmıştır. Çalışmanın bu bölümünde, TBA kullanılarak yüz tanımaya odaklanan bazı önemli araştırmalardan bahsedilmiştir.

Zhou ve arkadaşları TBA görüntüsü rekonstrüksiyonu ve DDA'ya dayalı yüz tanımayı inceledi. Yüz tanıma için TBA ve DDA kullandılar. Oluşturulan matris olarak öznitelik çıkarımı için iç sınıf konvaryans matrisini ve elde edilen her kişiden özvektörleri kullanmayı önerdiler. Daha sonra yeniden yapılandırılmış görüntüler elde ettiler. Önerilen yöntem ORL yüz veri tabanında etkilidir (Zhou vd., 2013).

Wang ve arkadaşları yeni, genelleştirilmiş TBA tabanlı yüz tanıma algoritması önerdiler. Algoritmanın aydınlatma sağlamlığını iyileştirmek için simetrik görüntü düzeltme (SGD) ve bit düzlemi özellik füzyonunu (BDÖF) geliştirdiler. Daha sonra, yüz tanımayı gerçekleştirmek için sanal yüzlere Genelleştirilmiş TBA uyguladılar. Çizimin sonuçları, yüz tanıma algoritmasına yönelik kombine yaklaşımın duyarlılıktaki farklılıkları azaltmada etkili olduğunu göstermiştir (Wang vd., 2007).

Hsieh ve Tung, yüz tanıma için alt model tekniğine ve beyazlatılmış TBA'ya bağlı yeni bir hibrit yaklaşım geliştirdi. Araştırmalarında, yüz tanıma için alt desen tekniğini sırasıyla TBA I ve TBA II ile birleştirdiler. Çalışma, alt model tekniğinin TBA I için yararlı olduğunu, ancak TBA II ve TBA için yararlı olmadığını gösterdi. Daha sonra yüz tanıma için TBA II ve Sp-TBA'yı birleştirdiler. Deneylerin sonuçları, önerilen yaklaşımın diğer geleneksel yöntemler kullanılarak elde edilen daha gelişmiş tanıma performansı sağladığını gösterdi (Hsieh ve Tung, 2009).

Luh ve Lin, TBA'ya dayalı yapay bağışıklık ağlarının yardımıyla bir yüz tanıma yöntemi önerdiler. Genetik algoritmaları kullanarak bağışıklık ağlarının antikorlarını optimize ettiler. Çalışmalarının sonuçları, önerilen yöntemin, geliştirilen yöntemlerin çoğunun aksine daha iyi tanıma oranına sahip olduğunu gösterdi (Luh ve Lin, 2011).

Kusuma ve Chua, yüz tanıma için görüntü rekombinasyonunun kullanımı hakkında bir araştırma önerdi. Görüntülerde maksimum varyans miktarını kullanarak ve 2D ve 3D görüntülerinin farklı yüz ifadelerinin verilerinin eksen dönüşümünü bularak 2D ve 3D yüz tanıma yöntemlerini birleştirdiler. Görüntü piksel rekombinasyonunun veya puan seviyesi füzyonuna dayalı diğer yüz tanıma sistemlerinin kullanılmasının sonuçları iyi performans gösterdi (Kusuma ve Chua, 2011). Ayrıca, yüz tanıma için görüntü rekombinasyonundaki modaliteler arasındaki bağımlılık düzeyinde görüntü önerdiler. Yine 2D ve 3D yüz tanıma yöntemlerini birleştirdiler ve sonuçlar bir yıl önceki araştırmalarında olduğu gibi faydalı oldu (Kusuma ve Chua, 2011).

Oh ve arkadaşları, genel yüz tanıma sistemi tabanlı polinom radyal temel işlevli sinir ağlarının işlevsel bileşenlerinden birini önerdiler. Sistemleri, ön işleme ve tanıma modülünden oluşuyordu. TBA, YİÖ, D-TBA ve D-YİÖ gibi diğer algoritmalarla

karşılaştırıldığında TBA-DDA birleşik algoritmasının verimliliğini sundular (Oh vd., 2013).

Zhang ve Zhou, görüntülerin sütun yönünde çalışan etkili yüz gösterimi ve tanıma için alternatif bir iki boyutlu TBA (İBTBA) önerdiler. İki yönlü İBTBA'yı geliştirdiler. ORL ve FERET yüz veri setlerinin alt kümesine ilişkin deneysel sonuçlar, yöntemlerinin İBTBA ile aynı veya hatta daha yüksek tanıma doğruluğuna ulaştığını göstermiştir (Zhang ve Zhou, 2005).

Tan ve Chen, yüz tanıma için uygulanabilir ağırlıklı alt örüntü TBA'yı inceledi. Yöntemleri, doğrudan görüntünün orijinal tüm modelinden bölümlenen görüntünün alt modeli üzerinde işlemiştir. Ayrıca, yöntemleri, her bir parçanın karkılarını uyarmalı olarak hesaplayabilir ve daha sonra, hem ifade hem de aydınlatma varyasyonları için sistemin sağlamlığını geliştirmek için bunları bir sınıflandırma görevine bağlar. Üç standart yüz veri tabanı üzerinde yapılan deneyler, yöntemlerinin rekabetçi olduğunu göstermektedir (Tan ve Chen, 2005).

Abeer ve arkadaşları, çok doğrusal komşuluğu koruyan projeksiyonu inceledi. Yüz tanıma için projeksiyonu koruyan, denetimli ve denetimsiz çok doğrusal komşuluk için yeni bir yöntem önerdiler. Tensör uzayının sırasını kullanarak yöntemle üretilen alt uzayların sayısını belirlediler. Araştırmada varsayılan yöntemin performansı ORL, AR ve FERET yüz veri setleri kullanılarak analiz edilmiştir. Çalışmanın sonuçları, MNPP'nin hata oranı açısından standart yaklaşımlardan daha iyi performans gösterdiğini göstermiştir (Al-Shiha vd., 2014).

Banerjee ve arkadaşları, değişen aydınlatma koşulları altında yüz tanıma için bir frekans alanı doğrusal olmayan korelasyon tekniği önermiştir. Teknikleri, optimum yansıtılan görüntü filtresi ile optimum yeniden yapılandırılmış görüntü korelasyon filtresi arasındaki faz korelasyonuna dayanır. Performanstaki gelişme, görüntü piksellerinin nokta bazlı doğrusal olmayan özelliklerinden yararlanılarak elde edilir. Ayrıca, korelasyon tepe noktasını maksimize ederken korelasyon düzlemindeki enerjiyi en aza indirerek daha fazla optimizasyona yol açacağını öne sürdüler. Önerilen şema, standart yüz veri tabanları kullanılarak analiz edilmiştir, performansın diğer

standart kısıtlanmamış korelasyon filtrelerine kıyasla arttığını göstermektedir (Banerjee ve Datta, 2014).

Givens ve arkadaşları, istatistiksel yöntemler kullanarak yüz tanıma için biyometrik performans değerlendirmesini inceledi. İstatistiksel muhakeme, ağırlıklı olarak tanıma algoritmalarının tasarımında uygulanmıştır. Yaklaşımlardan biri özdeşleşmeye çalışır, öznelerin özelliklerini nasıl karşılaştırır ve yorumlar. Diğer bir yaklaşım, bazı zorlu yüz veri kümelerinin genelleştirilmiş doğrusal karışık model analizi ile gösterilmiştir. Çok değişkenli istatistikler, boyut küçültme, sınıflandırma vb. alanlardaki tanıdık istatistiksel fikirlerden muzdarip olan bazı yüz tanıma algoritmaları olsa da, alan bazı benzersiz özellikler ve zorluklar sunar (Givens vd., 2013).

Li ve arkadaşları, çok ölçekli Weber Yerel Tanımlayıcıları (WYT'ler) ve çok seviyeli bilgi füzyonunu kullanarak yüz tanıma için bir yöntem geliştirdiler. Araştırmalarında aşağıdaki dört adımı içeren bir yöntem sunarlar (Li vd., 2013):

1. Görüntü bölümü

2. Özellik çıkarma

3. Ölçüm özellikleri ve

4. Oylama

Önerilen modelleri ve sonuçları, üç popüler veri kümesi üzerinde etkililik gösterdi.

Luan ve arkadaşları, doğrusal regresyon ve seviye belirleme yöntemlerini kullanarak bitişik oklüzyonlu yüz tanımayı inceledi. Bölme şeması kullanmadan bitişik tıkanmaya karşı yüz tanıma için yeni bir yöntem önerdiler. Bunun arkasındaki fikir, tıkanmaların doğrusal regresyon tabanlı sınıflandırma (DRTS) yöntemi üzerindeki etkisini ortadan kaldırmaktır. Yaklaşımlarında, DRTS'den türetilen hata görüntüsünün, tıkalı bölgeleri tanımlamak için orijinal görüntüden daha iyi bir seçim olduğunu analiz ettiler. Tıkalı bölgeleri belirlemek için bozuk piksellerin uzamsal sürekliliğinin nasıl etkili bir şekilde kullanılacağını sundular. Elde ettikleri sonuçlar,

önerilen yaklaşımın farklı tipteki tıkanmalara karşı etkinliğini göstermektedir (Luan vd., 2013).

2.3 Yüz Tanıma için Kullanılan Yöntemler

Pek çok görüntü işleme yöntemi olmasına rağmen, sadece bazıları yüz tanıma problemini çözebilir. Yüz tanıma için kullanılan yöntemler aşağıdaki şekilde sınıflandırılabilir:

i. Bütünsel Yöntemler

ii. Yerel Yöntemler

iii. Hibrit yöntemler

2.3.1 Bütünsel Yöntemler

Önerilen birçok genel yüz tanıma algoritması vardır. Bunların arasında, yüz tanıma araştırma topluluğu üzerinde çok büyük etkisi olan ve sayısız çalışmaya ilham veren iki algoritma vardır. Bunlar öz yüzler ve balıkçı yüzleridir.

2.3.2 Yerel Yöntemler

Yerel yüz bölgelerine dayalı yüz tanıma, önemli miktarda ilgi çekmiştir çünkü yerel özelliklerin yüz ifadesi, aydınlatma ve tıkanma çeşitlerine karşı daha sağlam olduğuna inanılmaktadır. Yerel bölgeleri kullanan yaklaşımlar ya çıkıntı bölgeleri kullanır ya da sadece yüz görüntüsünü dikdörtgen bloklara böler. Yüz Tanıma için Bütünsel Yaklaşım Şekil 2.1'de gösterilmektedir.

Şekil 2.1 Yüz Tanıma için Bütünsel Yaklaşım

2.3.3 Hibrit Yöntemler

Hibrit yöntemler, iki veya daha fazla yüz tanıma yaklaşımı içeren yöntemlerdir. Tekil yaklaşımlar yüz tanıma sorununa yeterli çözüm sağlayamadığından, araştırmacılar, tanıma performansını iyileştirmek için bir veya daha fazla farklı özellik türü kullanılarak çıkarılan küresel ve yerel bilgileri birleştirme eğiliminde olmuştur.

2.3.4 Temel Bileşen Analizi (TBA)

Temel bileşen analizi (TBA), çok değişkenli bir istatistiksel tekniktir. Amacı, kapsamlı kayıtları yapılandırmak, basitleştirmek ve çeşitli istatistiksel değişkenlerle daha az sayıda anlamlı olası doğrusal kombinasyonlara ("ana bileşenler") yaklaşılarak göstermektir. Spesifik olarak, görüntü işlemede, ana bileşen analizi, Karhunen-Loéve dönüşümü olarak da adlandırılır. Biçimsel benzerliği olan ve faktörleri çıkarmak için bir yaklaşım yöntemi olarak kullanılabilecekleri faktör analizinden ayırt edilmelidirler. (İki yöntem arasındaki fark, madde faktör analizinde açıklanmıştır). Örneğin, TBA'nın çeşitli genellemeleri vardır. Ana Eğriler, Ana Yüzeyler veya çekirdek TBA. Veri sunumu ve boyut azaltımına bir örnek, şekil 2.2'de gösterilmektedir.

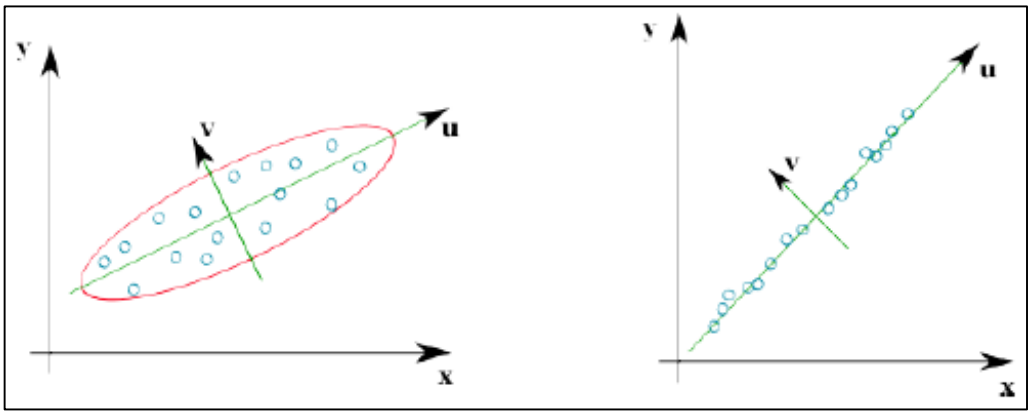

Şekil 2.2 Boyut Azaltma (sağ) ve Veri Sunumu (sol) için TBA

3. METODOLOJİ

3.1 Derin Sinir Ağı

Bu bölümde, yapay sinir ağı modelinin çalışmasıyla ilgili kavramlara odaklanarak derin öğrenmeye bir giriş ile başlayacağız. Derin sinir ağı (DSA) veya yapay sinir ağı (YSA), derin öğrenme alanının en genelleştirilmiş sinir ağıdır. Bu ağlar bir tür bilgi işlem sistemleridir ve ilhamlarının ana kaynağı, hayvan beyinlerinin gerçek hayat veya biyolojik sinir ağlarıdır. YSA, esas olarak yapay nöronlar olarak adlandırılan bağlı düğümler veya birimlerden oluşur ve gerçek bir biyolojik beyindeki nöronları gevşek bir şekilde taklit eder. Şekil 3.1 tipik bir biyolojik ve yapay sinir ağını karşılaştırmaktadır. Biyolojik bir beyindeki sinapslara benzeyen bu yapay nöronlar arasındaki her bağlantı, bu tür yapay nöronların çoklu katmanları arasından bir sinyal iletmek için kullanılır. Her yapay nöron sinyali aldıktan sonra onu işler ve ardından kendisine bağlı diğer ek yapay nöronları iletir veya sinyal verir.

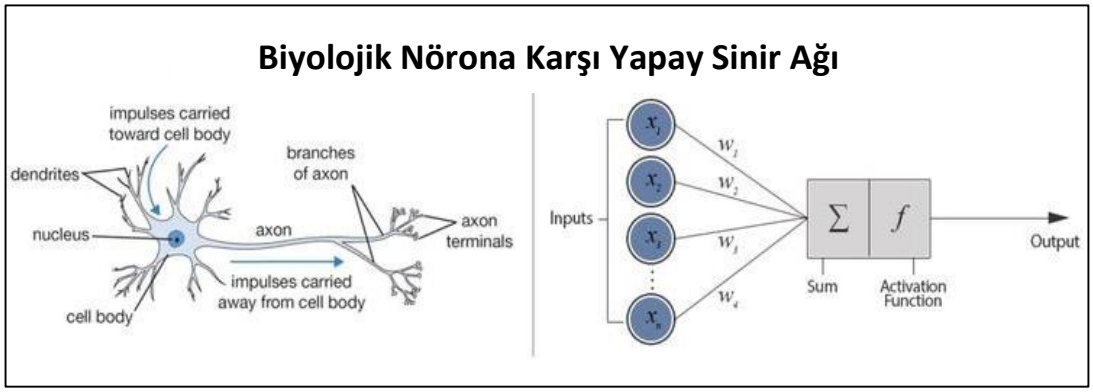

Şekil 3.1 Biyolojik nöron ve YSA (Roell, 2017)

YSA uygulamalarının çoğunda, nöronlar arasındaki veriler gerçek bir sayı kullanılarak temsil edilir ve ilk hesaplamayı yaptıktan sonra (ağırlık çarpımı ve önyargı eklenmesi), her bir yapay nöronun çıktısı, bazı doğrusal olmayan işlevlerle (aktivasyon işlevi) girdilerinin toplamı daha da işlenir. Yapay nöronlar arasındaki bağlantılara kenarlar denir. Tüm yapay nöronlar ve bunlara karşılık gelen kenarları, tipik olarak kendileriyle ilişkili bir ağırlığa sahiptir ve bu, öğrenme ilerledikçe ayarlanmaya veya güncellemeye devam eder. Her bağlantının gücü ağırlık değerine bağlıdır, ağırlık değerlerindeki değişimle artar ve azalır.

Yapay nöronların kendileriyle ilişkili bir eşiği de olabilir ve bu, sinyalin yalnızca 0 veya 1 üretmek için belirli bir eşiğe ulaşan bir nörondaki ağırlıklı giriş toplamına bağlı olarak daha fazla aktarıldığı anlamına gelir (çıkış 0 veya 1). Tipik olarak, yapay nöronlar çoklu katman şeklinde düzenlenir. Farklı katmanlar, alınan girdi verilerine farklı türde bir işlem veya dönüşüm gerçekleştirmekten sorumludur. İlk katmandan (giriş katmanı) son katmana (çıktı katmanı) giden her sinyal, muhtemelen bu katmanlardan birden çok kez geçebilir. Öğrenme oranlarını hızlandırmak için, gradyan inişi için RMSProp'u (Hinton vd., 2012) kullanıyoruz, bu ağırlık öğrenme oranını bu ağırlık için son gradyanların büyüklüklerinin hareketli ortalamasına böler (Tripathi vd., 2017).

3.1.2 Aktivasyon Fonksiyonu

Bir aktivasyon fonksiyonu, ağırlıklarla çarpıldıktan ve önyargı kısmı eklendikten sonra tek bir değere dönüştürülen çoklu nöronun birleşik çıktısını almaktan sorumludur. Bu değeri aldıktan sonra üzerine bir doğrusal olmayanlık uygular. Doğrusal olmayan fonksiyonun burada uygulanmasının nedeni, tüm gerçek hayat problemlerinin doğrusal bir çözüme sahip olmamasıdır. Bu nedenle, çözüm eğrisini şekillendirmek ve temeldeki veri noktalarına uymak için aktivasyon fonksiyonlarının kullanılması gereklidir. Şimdi, bir tür doğrusal olmayanlık üretebilecek herhangi bir işlevin etkinleştirme işlevi için olası bir aday olduğunu düşünebiliriz, ancak bu doğru değildir. Son zamanlarda araştırma çalışmalarında kullanılan bazı popüler aktivasyon fonksiyonlarına kısaca bir göz atacağız.

3.1.2.1 Sigmoid işlevi

Sigmoid işlevi aynı zamanda lojistik işlev olarak da bilinir, günümüzde kullanılan en eski aktivasyon işlevlerinden biridir. Girişinin değerini [0,1] aralığında sınırlandırması popülerdir. Yapay sinir ağlarının ilk günlerinde popüler bir seçimdi. Çoğunlukla sınıflandırma görevlerinde kullanılır (Han ve Moraga, 1995).

$$\sigma(x) = \frac{1}{1+e^{-1}} \tag{2.1}$$

Bu şekil, Şekil 3.2'de gösterilmiştir.

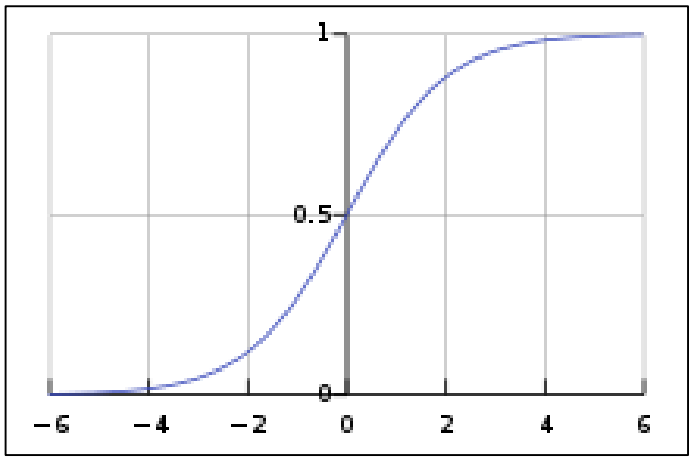

Şekil 3.2 Sigmoid.

3.1.2.2 Doğrultulmuş doğrusal birim (DDB)

Doğrultulmuş doğrusal Birim, girdi argümanlarında pozitifliği arayan bir aktivasyon fonksiyonudur. Girdi değeri pozitifse olduğu gibi döndürülür, aksi takdirde değer sıfırdan küçükse son çıktı değeri olarak sıfır (0) döndürülür. DDB'yi hem YSA hem de CNN modellerinde aktivasyon fonksiyonu olarak kullandık. Şekil 3.3, düzeltilmiş doğrusal birim grafiğini temsil etmektedir. DDB için ifade aşağıdaki gibidir (Nair ve Hinton, 2010):

$$y = x^{+} = \max(0, x) \tag{2.2}$$

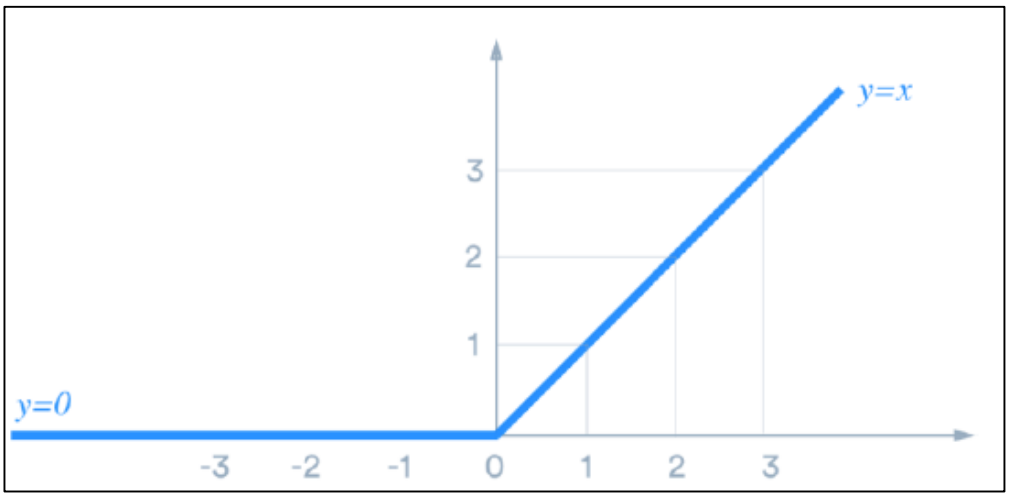

Şekil 3.3 Doğrultulmuş doğrusal birim (Liu, 2017)

3.1.2.3 Hiperbolik tanjant (tanh)

Hiperbolik bir şekilde sigmoid işlevi gibi şekillenir, ancak çıktı değerleri her zaman [-1, 1] aralığında bulunur. Tanh için ifade şu şekildedir (Nwankpa vd., 2018):

$$f(x) = \frac{(e^{x} - e^{-x})}{(e^{x} + e^{-x})} \tag{2.3}$$

Hiperbolik tanjant (tanh) şekil 3.4'te gösterilmektedir.

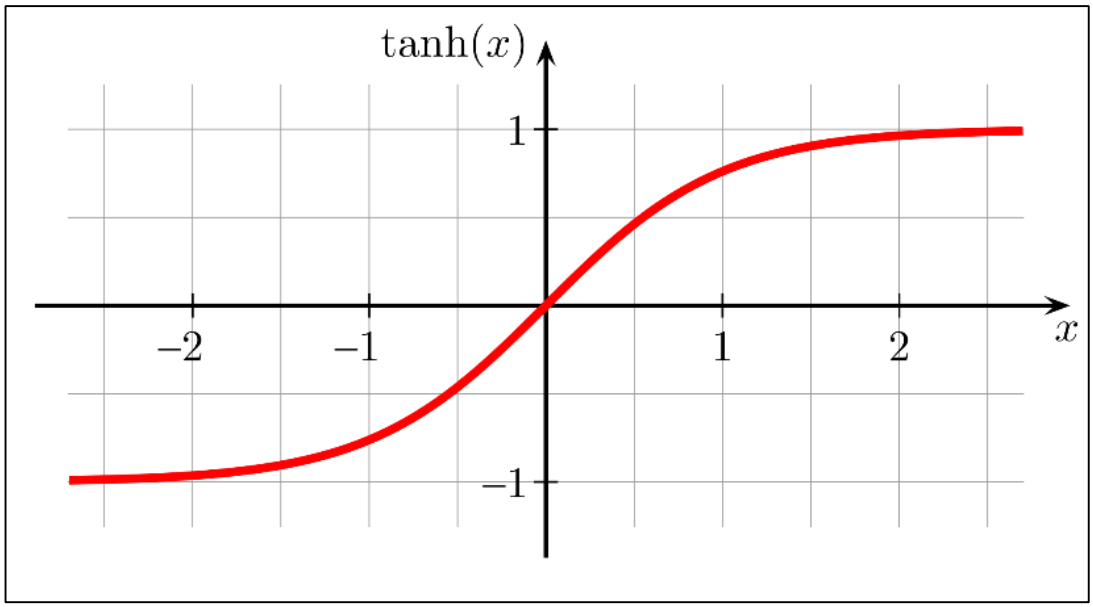

Şekil 3.4 Hiperbolik tanjant (tanh).

3.1.2.4 Softmax işlevi

Softmax işlevi, çıktı nöronları üzerinden normalleştirilmiş bir olasılık dağılımı döndürür. Çoğunlukla çok sınıflı sınıflandırmada kullanılır, çünkü her sınıf için maksimum değerin nihai sınıf olarak döndürüldüğü olasılık değerleri sağlar (Nwankpa vd., 2018).

Softmax, modelimizin son katmanları için bir aktivasyon fonksiyonu olarak kullanılmıştır.

$$softmax(x)_j = \frac{e^{xj}}{\sum_m e^{x}m} \tag{2.4}$$

3.1.3 Maliyet Fonksiyonu

Aktivasyon fonksiyonlarının yanı sıra, bir modeli eğitirken dikkat etmemiz gereken bir diğer önemli husus da maliyet fonksiyonudur. Tüm öğrenme modellerinin kendileriyle ilişkili maliyet işlevi vardır ve kullanım durumumuz için en iyi modeli bulmak için yaptığımız şey, maliyet işlevini en aza indirmemizdir. Burada bir maliyet fonksiyonunun rolünü ve kullanım durumumuz için mükemmel bir model elde etmemizi sağlayacak şekilde bir fonksiyonu nasıl optimize ettiğini inceleyeceğiz. Bu süreci adım adım inceleyelim,

1. Belirli bir giriş veri vektörü X ve karşılık gelen etiketler $\hat{y}$ ile. Bir maliyet fonksiyonunun işi, önce bu verilen $\hat{y}$ değeri ile modelin tahmin edilen 'y' çıktısı arasındaki farkı hesaplamaktır.

2. Tüm örneklerdeki bu fark daha sonra toplanır ve çoklu ağırlık değerlerine göre farklılaştırır.

3. Farklılaştırmanın sonucu daha sonra öğrenme hızı parametresi çarpma adımına aktarılır. Öğrenme oranı bir adım gibidir, hedefimize doğru büyük adımlar atmak istemiyoruz ve daha küçük adımlardan da kaçınıyoruz.

4. Bu farklılaştırma sonuçları ve öğrenme oranı ürünü daha sonra mevcut ağırlık değerlerini güncellemek için kullanılır.

$$E(W,b) = \frac{1}{N}\sum_{n=1}^{N} E(W,b;\ x_n, y_n) \tag{2.5}$$

Burada N, toplam örnek sayısıdır. En sık kullanılan maliyet fonksiyonları aşağıdaki gibidir:

3.1.3.1 Hatanın karesi toplamı (HKT)

Daha önce bahsettiğimiz gibi, bir maliyet fonksiyonu, veriler ile bir tahmin modeli arasındaki tutarsızlığın bir ölçüsüdür. HKT'nin değerini düşürün, model uyumu daha iyileşir.

$$SSE(y, \hat{y}) = \sum(y_n - \hat{y}_n)^2 \tag{2.6}$$

3.1.3.2 Kategorik çapraz-entropi (KE)

Kategorik çapraz-entropi, esas olarak sinir ağlarının eğitiminde kullanılan maliyet fonksiyonudur. Bu modellerde kullanılmasının iki ana nedeni vardır, bunlardan birincisi, her zaman negatif değildir, yani KE > 0'dır. İkincisi, gradyan inişli geri yayılımı kullanan eğitim sürecidir (bunu sonraki paragrafta ele alacağız).

$$CE(y, \hat{y}) = -\frac{1}{N}\sum_{n=1}^{N}\sum_{k=1}^{K} -y_n^k \log(\hat{y}_n^{(k)}) \tag{2.7}$$

Yukarıdaki denklemde K, sınıfların sayısıdır. K = 2 ile ikili KE durumunda KE aşağıdaki gibidir:

$$CE(y, \hat{y}) = -\frac{1}{N}\sum_{n=1}^{N} y_n.\log(\hat{y}_n) + (1 - y_n).\log(1 - \hat{y}_n) \tag{2.8}$$

3.1.4 İyileştiriciler

Optimize edici işlevler, maliyet işlevini en aza indirmek için kullanılır ve bu nedenle, ağırlıklar 'w' ve sapmalar 'b' gibi öğrenilebilir parametreleri güncellemek için kullanılır. Optimize edilmiş öğrenilebilir parametrelerle, x girdi bilgisi değişkeni kullanılarak ve modeli birkaç dönem boyunca eğiterek elde edilen geliştirilmiş bir y tahmini değeri elde edebiliriz. Etkili bir model eğitimi için iyi bir optimize edici işlevin seçilmesi gerekir. Şimdi, sinir ağlarının eğitiminde kullanılan çeşitli optimize edici işlevlere bakacağız. Optimizasyon algoritmaları esas olarak iki kategoriye ayrılır.

1. *Birinci dereceden optimizasyon algoritmaları*: Bu algoritmalar, gradyanı hesaplamak için maliyet fonksiyonunun farklılaşmasını kullanır ve daha sonra, ağırlıkları ce sapma değerlerini güncellemek için bu gradyan değerini kullanır. Bu tür algoritmaların popüler bir örneği Gradyan İnişi'dir. Birinci dereceden türev bize fonksiyonun herhangi bir noktada artıp azalmadığını söyler.

Burada gradyan terimi, bir fonksiyonun birinci dereceden türevini temsil etmez, örneğin $\frac{dy}{dx}$, 'x' değişkenine göre 'y' değişkeninin değerindeki değişimi temsil eder ve bu bir birinci dereceden türevdir. Öte yandan, birçok parametreyi eğittiğimiz sinir ağları durumunda, kısmi türev tekniği kullanılır ve bu, birden fazla değişkenin gradyanını elde etmek için birinci dereceden türevin yerini gradyanın aldığı yerdir. Dolayısıyla, genel olarak, birden fazla değişkenin farklılaşması ile uğraşırken ve kısmi türevler kullandığımızda, buna sadece birinci dereceden türetme değil, gradyan hesaplaması denildiğini söyleyebiliriz.

2. *İkinci dereceden optimizasyon algoritmaları:* Bu algoritmalar, öğrenilebilir parametrelerin güncellenmesi için gereken gradyanı hesaplamak için maliyet fonksiyonunun ikinci dereceden kısmi türevini kullanır. Ancak bildiğimiz gibi ikinci dereceden türevin hesaplanması maliyetli olabilir ve bu yüzden bu algoritmalar pek kullanılmamaktadır.

Hangi sırayla optimizasyon stratejisinin kullanılacağı: Hesaplaması kolay olduğu ve daha hızlı yakınsadığı için çoğunlukla birinci dereceden optimizasyon tercih edilir. İkinci dereceden optimizasyon ancak ikinci dereceden türev bilindiğinde kullanılabilir, bunlar maliyetli ve zaman alıcıdır.

Sinir ağlarında kullanılan çeşitli optimizasyon algoritmalarına bakalım.

3.1.4.1 Gradyan inişi

Gradyan inişi, sinir ağları için kullanılan en popüler optimizasyon algoritmalarından biridir. Gradyan inişiyle ilgili ifade şöyledir: $\tau = \tau - \eta\Delta J(\tau)$. Burada τ, değerleri her yinelemede güncellenen öğrenilebilir parametrelerdir. η öğrenme oranıdır, ΔJ ise maliyet fonksiyonunun τ parametresine göre gradyanıdır.

Gradyan inişi, modelin önce ileri yayılımı kullanarak bir değer tahmin etmesinden sonra gerçekleşen geriye doğru yayılma anında devreye girer. Bu tahmin edilen değerle, maliyet fonksiyonu hesaplanır ve ardından bu hatanın ağırlıklara veya diğer

parametrelere göre gradyanı hesaplanır. Gradyan inişinin iki popüler türü vardır: Stokastik gradyan inişi (SGİ) ve mini-toplu gradyan inişi.

Stokastik grafyan inişi, standart gradyan inişine göre bir iyileştirme olarak tanıtıldı çünkü standart yaklaşım çok fazla çok fazla zaman alıyordu ve aynı anda tüm veri setinin değerlerini güncelliyordu. Öte yandan SGİ, bir seferde bir seferde tek bir örnek için değerleri günceller, $\tau = \tau - \eta\Delta J(\tau, x(i), y(i))$. SGİ kullanılarak ağırlık güncellemesi aşağıdaki şekilde yapılabilir:

$$\Delta w_i(\tau + 1) = -\alpha \frac{\partial E}{\partial w_i} \tag{2.9}$$

$$w_i(\tau + 1) = w_i(\tau) + \Delta w_i(\tau + 1) \tag{2.10}$$

$\Delta w_i(\tau + 1)$ ağırlık güncellemesi olduğunda, α burada adım boyutuna karar veren öğrenme oranıdır ve τ yineleme değişkenidir. Aynı güncelleme süreci sapma için de uygulanabilir.

Şimdi, SGİ ile zaman tüketimi sorunu çözülmüş olsa da, küresel minimuma doğru aşırı arama sorunu ortaya çıktı. Bu sorunu çözmek için, temel örneklerin toplu işlerinde parametreleri güncelleyen mini toplu gradyan inişi tanıtıldı. Genellikle mini parti boyutları 50 ila 256 arasında değişir, ancak uygulamaya ve kullanım durumuna bağlı olarak herhangi bir sayı olabilir. Gradyan iniş ve varyantlarını kullanırken karşılaşılan bazı zorluklar şunlardır:

1. Gradyan iniş kullanımında karşılaşılan ilk zorluk, iyi bir öğrenme oranı değeri seçmektir. Çok küçük bir değer, modelinizin küresel minimumda birleşmesinin sonsuza kadar süreceği anlamına gelir ve bu hiç de kabul edilemez. Başka bir sorun da, öğrenmenin çok fazla olduğunu kanıtlaması olabilir, bu da modelin aşmaya devam edeceği ve olması gereken noktaya asla ulaşamayacağı anlamına gelir.

2. Ek olarak, tüm parametre güncellemeleri için aynı öğrenme oranı kullandığımızdan, kullanılan veriler seyrek olduğunda bu iyi bir yaklaşım olmayabilir. Bu durumunda özellikler çok farklı bir frekansta gerçekleşir, bu,

nadiren ortaya çıkan bir özelliğe karşı her zaman meydana gelen eşit bir özelliğin güncellenmesi iyi bir seçim olmadığı anlamına gelir. Nadiren ortaya çıkan özellik, her yerde bulunanlara kıyasla daha büyük güncellemeler almalıdır.

3. Gradyan inişinin karşılaştığı bir diğer önemli sorun, bir boyutun yukarı ve diğerinin aşağı eğimli olduğu noktalar olan yerel minimum veya eyer noktaları olduğunda dışbükey olmayan maliyet fonksiyonları durumudur. Bu eyer noktaları çoğu zaman aynı hatanın platosuyla çevrilidir, bu da gradyan sıfır olduğu için SGİ'nin bundan kaçmasını tüm yönler veya boyutlarda zorlaştırır.

3.1.4.2 Adagrad

Adagrad durumunda, 'η' öğrenme temeldeki parametrelere adapte olabilir. Bu nedenle, parametrelerin oluşma sıklığına bağlı olarak farklı öğrenme oranları sağlanır. Bir parametre sık sık meydana gelirse, düşük bir öğrenme oranı alırken, bir parametre nadiren meydana geliyorsa, büyük öğrenme oranı güncellemeleri alacaktır. Bu uyarlanabilir nedenden dolayı seyrek verilerle kullanılır. Daha önce, tüm θ parametreleri aynı η öğrenme oranını kullanarak olduğu gibi, tüm θ(i) parametreleri için bir kerede güncelleme gerçekleştiriyorduk. Şimdi, adagrad ile her zaman 't' adımında her parametre için farklı öğrenmeye sahibiz.

Adagrad'ı kullanmanın en büyük yararı, başlangıç noktasında 0,01 gibi bir değerle başlatıldığından ve öyle bıraktığından, öğrenme oranını bizim tarafımızdan manuel olarak ayarlamamıza gerek kalmamasıdır. Öte yandan, temel zayıflığı, öğrenme oranının -η'nın düşmeye ve azalmaya devam etmesidir. Bu, sırayla modelin daha hızlı öğrenme yeteneğini azaltır ve sonuçta bu, modelin eğitilmesi ve optimum bir parametre setine yakınlaşması için çok uzun zaman aldığı anlamına gelir. Bu yavaş yakınsama sorunu, şimdi ele alacağımız başka bir optimize edicide ele alınmaktadır.

3.1.4.3 Adadelta

AdaDelta, adagrad ile daha önce yaşadığımız bozunma sorununu ortadan kaldırdığı için adagradın bir uzantısıdır. Son optimize edicideki öğrenme oranının azalmasının arkasındaki ana neden, paydasında gradyan değerlerinin birikmesiydi. AdaDelta'da ise

gradyan değerlerinin sayısı kontrol altında tutulur ve sadece ağırlık parametreleri ‘w’ ile ilişkili belirli sayıda gradyanların birikmesine izin verilir. Dolayısıyla, önceki tüm gradyan değerlerinin karesi alınmış toplamını dikkate almak yerine, geçmiş kare gradyanların bozunma ortalaması olarak tanımlanır.

3.1.4.4 Adam

Adam, Uyarlanabilir Moment Tahmini’ni temsil etmektedir. Her bir parametre için uyarlanabilir bir öğrenme oranı hesaplamanın başka bir yaklaşımıdır. Adam, tüm gradyan değerlerinin geçmiş kare toplamının üssel olarak azalan ortalamasını depolamanın yanı sıra, geçmiş gradyanların katlanarak azalan bir toplamını da tutar.

Adam, daha hızlı yakınsadığı ve modelin genel öğrenme hızı aynı zamanda oldukça hızlı ve verimli olduğu için diğer uyarlanabilir optimize edicilerle karşılaştırıldığında pratikte iyi çalışıyor. Ayrıca, kaybolan öğrenme hızı, yüksek varyans veya bazen yavaş yakınsama gibi diğer optimize edici işlevlerde gözlemlenen ve parametre güncellemeleri sırasında dalgalı bir kayıp işlevine yol açabilecek diğer sorunları da düzeltir.

3.1.4.5 Rmsprop

RMSprop, sinir ağları için tasarlanmış, yayınlanmamış bir ayarlanabilir öğrenme hızı optimizasyon algoritmasıdır. Henüz yayımlanmaması çok popüler değildir ve çok iyi bilinmemektedir ve birçok derin öğrenme çerçevesi RMSprop için kutudan çıkar çıkmaz uygulama sağlar. RMSprop, uyarlanabilir öğrenme oranı yaklaşımı nedeniyle Adagrad’a çok benzediği için Adagrad ile karşılaştırılarak anlaşılabilir. Adagrad ile, zamanla öğrenme oranının düşmeye devam ettiği anlamına geldiğinden, birikmiş kare gradyan toplamıyla ilgili sorunlarımız vardı. Ve bir süre sonra, düşük öğrenme oranı değeri nedeniyle adım boyutu o kadar küçük hale geldi ki, model zamanında bir araya gelemedi. Öte yandan, RMSprop ile kare gradyanların tahminini tutuyoruz, ancak eğitim boyunca gözlemlenen tam tahmin değerleri değil, yalnızca hareketli bir ortalama CNN modelimiz için optimize edici olarak RMSprop’u kullandık ve birden fazla test sonucu elde ettik.

Sonuç notunda, eğer kullanılan veriler seyrekse, SGİ ve momentum gibi yöntemlerin daha düşük olduğunu ve kötü performans göstereceğini söyleyebiliriz. Seyrek veri kümeleri için uyarlanabilir öğrenme hızı optimize edici kullanılmalıdır.

Bu, günümüzde sinir ağlarında kayıp işlevi optimizasyonu için kullanılan optimize edicilere genel bir bakıştı. Şimdi Derin Sinir Ağı modelimizin mimarisine geçeceğiz. Mimari ayrıntılar, modelin çeşitli katmanlarını (girdi, hem çıktı hem de gizli) kapsar. Her katmanda kullanılan birkaç nöronun bir tahmini de sağlanmıştır, çeşitli kombinasyonların ayrıntılı açıklaması sonuçlar bölümünde mevcuttur.

3.2 Model Mimarimiz

Kullandığımız YSA modeli (Şekil 3.5) şunlardan oluşur:

1. Bir çıktı katmanı.

2. Üç gizli katman (nöron sayısı değişir).

3. Her gizli katman, aktivasyon işlevi olarak DDB kullanır.

4. Her bir gizli katmanın ardından bir bırakma katmanı gelir.

5. Modelin son katmanı çıktı katmanıdır (2 çıktı sınıfını temsil eden 2 nöron içerir).

6. Son katman veya çıktı katmanı, aktivasyon işlevi olarak Softmax'ı kullanır.

7. Model için kayıp işlevi, logitlerle Softmax çapraz entropidir.

8. Adam optimizer, YSA için kayıp optimize edici olarak kullanılır.

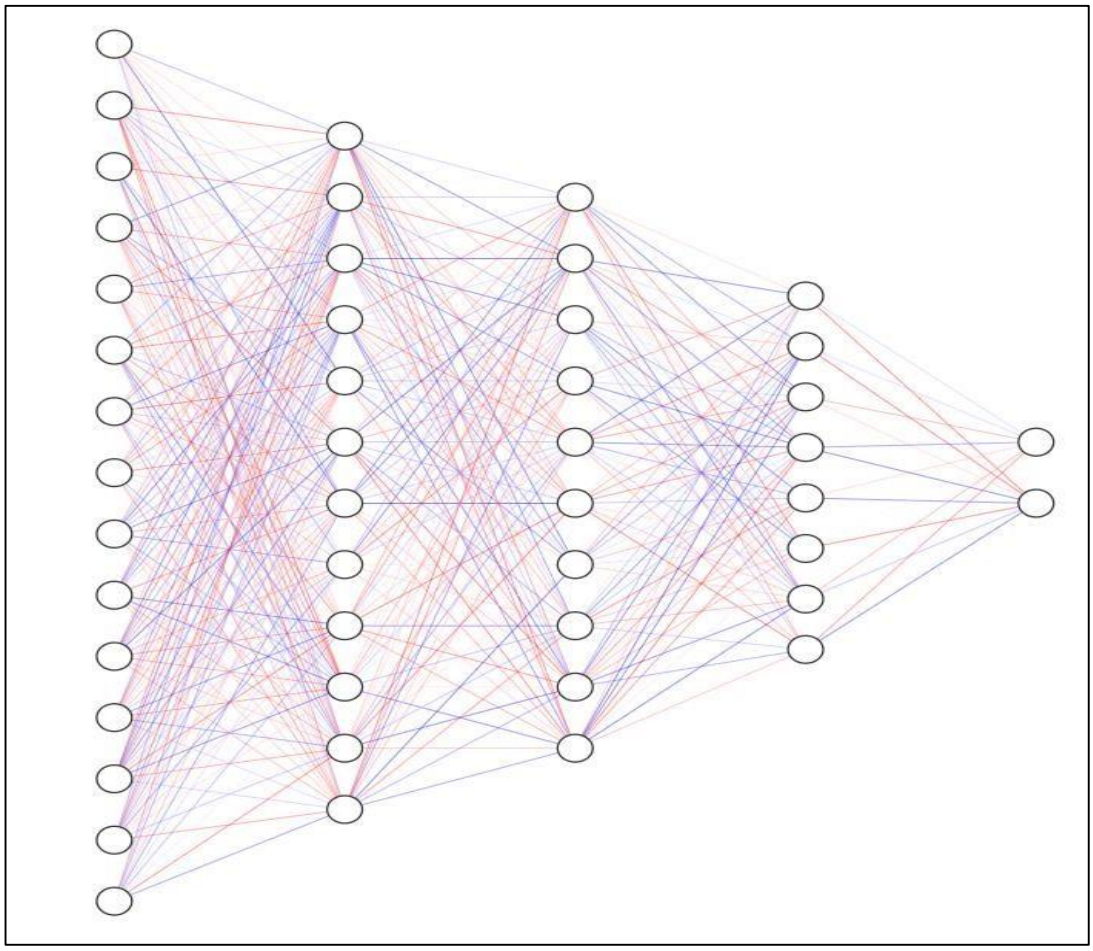

Şekil 3.5 YSA Minarisi (Lenail, 2020)

ESA olan ‘Evrişim Sinir Ağı’, en yaygın olarak görüntüleri analiz etmek için kullanılan derin, ileri beslemeli yapay sinir ağları sınıfıdır. Bu ağlar, ön işlemeyi en aza indirmek için tasarlanmış çok katmanlı algılayıcıların bir çeşidini kullanır.

Evrişimsel ağlar, nöronlar arasındaki bağlantı modelinin hayvan görsel korteksinin organizasyonuna benzemesi bakımından biyolojik süreçlerden esinlenmiştir. Bireysel kortikal nöronlar, uyaranlara yalnızca alıcı alan olarak bilinen görme alanının sınırlı bir bölgesinde yanıt verir. Farklı nöronların alıcı alanları, tüm görme alanını kaplayacak şekilde kısmen örtüşür.

ESA’lar çoğunlukla görüntü ve video tanımanın yanı sıra tıbbi görüntü analizi için kullanılır. Projemizde herhangi bir katılımcı için her videonun verilerini görüntü yaklaşımı olarak *sinyalimizde tek bir görüntü olarak* düşünüyorsak, burada her görüntünün çözünürlüğü (her video serisi) 8.064x32’dir. Ve bildiğimiz gibi, ESA’lar

diğer görüntü sınıflandırma algoritmalarına kıyasla nispeten daha az ön işleme kullanır. Bu, ağın geleneksel algoritmalarda elle tasarlanmış filtreleri öğrendiği anlamına gelir. Özellik tasarımında önceki bilgilerden ve insan çabasından bu bağımsızlık, büyük bir avantajdır. Bu avantajlara ek olarak, hesaplamaların karmaşıklığı ve ağırlıklar açısından kayıt tutma söz konusu olduğunda, ESA'larda filtrelerin kullanılması nedeniyle daha az sayıda ağırlık değerine sahibiz. Öte yandan DEA'da, verilerdeki temel modeli öğrenmek için nispeten çok sayıda ağırlık ve sapma değeri tutmamız gerekiyordu.

Kullandığımız modelin mimarisine geçmeden önce, evrişim ağlarında kullanılan çeşitli katmanların genel bakışına bir göz atacağız.

3.2.1.2 Evrişim katmanı

Bir evrişim sinir ağının (ESA) ana bileşeni evrişim katmanıdır. Bir evrişim katmanının arkasındaki yaklaşım, herhangi bir giriş için yerel olarak öğrenilen bir özelliğin (örneğin herhangi bir 2-D görüntü) aynı giriş kaynağının diğer bölgelerinde yardımcı olması gerektiğidir. Örneğin, görüntünün bir bölümünde yararlı olduğu kanıtlanan kenar algılama özelliği, olası bir genel özellik çıkarma aşamasında görüntünün diğer bölgelerinde yardımcı olabilir. Bir açıya veya eğrilere yönlendirilmiş kenarlar gibi bir görüntüdeki diğer özelliklerin öğrenilmesi, filtrelerin görüntü boyunca belirli bir evrişim katmanı için sabit olan bir adım veya adım boyutu kaydırılmasıyla elde edilir. Tipik bir evrişim tabakası filtre çalışması Şekil 3.6'da gösterilmektedir.

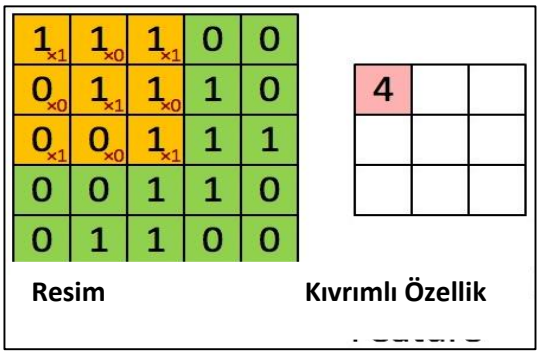

Şekil 3.6 Filtreli tipik bir evrişim katmanı (Jogin vd., 2018)

Buradaki, değerleri kırmızı renkte belirtilen 3x3 evrişim filtresinin, 5x5 görüntünün verilen giriş piksel değerlerinin üzerine uygulandığını görebilirsiniz. Her kutudaki ilgili değerler daha sonra çarpılır (9 değerin tümü için 1*1 + 1*0 + 1*1 + 0*0 vb.) ve toplam (yukarıdaki durumda 4 tür) burada kıvrımlı özellik olarak gösterilen çıktı. Görüntünün belirli bir bölgesi ile çarpıldıktan sonra filtre belirli bir adım değeri veya adım değeri kadar kaydırılır ve bu şekilde kaydırılarak tüm görüntü filtre ile kaplanır. Görüntünün şeklinin filtre uygulanamayacağı durumda, filtrenin eşit şekilde uygulandığından emin olmak için kenarlara dolgu yapılır. Bir görüntünün üzerinde kayma işlemine, aynı zamanda, bir görüntü gibi girdi için görüntünün yüksekliği ve genişliği olan, giriş boyutları üzerinde filtrelerin kıvrılması olarak da adlandırılır. Filtreler, girdi verilerinin veya görüntünün tam derinliğini kapsar, bir RGB görüntüsü durumunda olduğu gibi, evrişim filtreleri, derinlik boyutlarında üç kanalı (R,G ve B) kapsayacaktır. 8.064x32 boyutundaki video verilerimiz durumunda, filtrenin orijinal boyutunun (5,5) olduğu bulundu. Farklı evrişim katmanlarında, sırasıyla üç evrişim katmanında 10, 15, 20 olarak değişen sayıda çekirdek veya filtre kullandık.

ESA filtrelerinin standart bir yapay sinir ağı ile karşılaştırılmasında, filtrelerin tipik bir sinir ağındaki ağırlık değerleri ‘w’ gibi olduğu gözlemlenebilir. Evrişimli ileri geçiş, tek bir matris-vektör temsili olarak temsil edilebilir, $y = W.x$.

Burada y, evrişimden sonraki çıktı değeridir, W, filtre değerlerini temsil eden bir ağırlık matrisidir ve x, girdi görüntü piksel değerleridir. Tipik bir evrişim ağı, ardışık evrişimli katmanlar, havuzlama katmanları, bırakma katmanları, DDB etkinleştirmeleri, tamamen bağlı katmanlar ve aktivasyon işlevi olarak Softmax kullanan bir çıktı katmanından oluşur. Bir yüz tanıma modelinde (Lee vd., 2009) çeşitli evrişim katmanındaki özellik şekil 3.7^de gösterilmektedir.

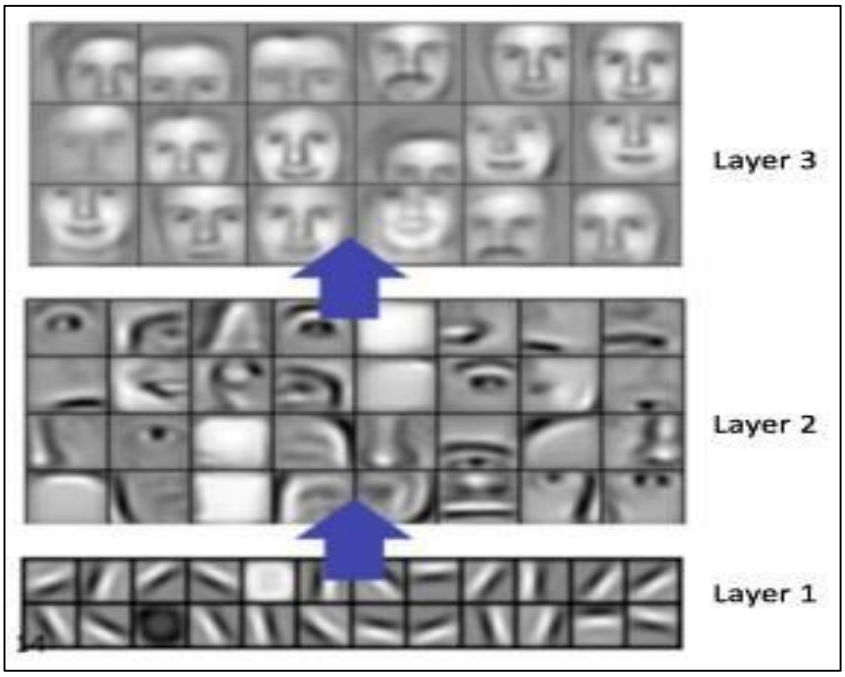

Şekil 3.7 Bir yüz tanıma modelinde çeşitli evrişim katmanında özellik (Lee vd., 2009)

Bir ESA durumunda, ayarlanabilir hiper parametreler, N filtrelerinin sayısı, boyutları K, filtrenin kaymasını gösteren adımlar ve sınırlarda fazla veri ve veri eksikliğinin nasıl ele alınacağı gibi çoktur (boyutların eşit olmaması durumunda) bu dolgudur. Tipik bir ESA'nın bir diğer önemli yönü, daha sonra ele alacağımız havuzlama katmanıdır.

3.2.1.3 Havuzlama katmanı

ESA'daki havuzlama katmanı, evrişim katmanı çıktı değerlerinin aşağı örneklemesi için kullanılır. Havuzlama katmanı, katlanmış katman çıktı değerlerini seçmek için kayan bir filtre de kullanır. Örneğin, bir maksimum filtre (belirli bir pencereden maksimum değerleri kullanan), minimum filtre (pencere değerlerinden minimum değerleri seçer) ve aynı zamanda bir ortalama filtre olabilir (penceredeki tüm değerlerin ortalamasını alır ve sonuç olarak geri döner). Aşağıdaki Şekil 3.8, maksimum havuz filtresini çalışırken gösterir. Bu şekilde havuz katmanı, gereksiz ve gerekli olmayan girdi özelliği değerlerinin kaldırılmasına yardımcı olur. Modelimizde ayrıca filtre boyutu (2,2) olan bir maksimum havuz filtresi kullandık.

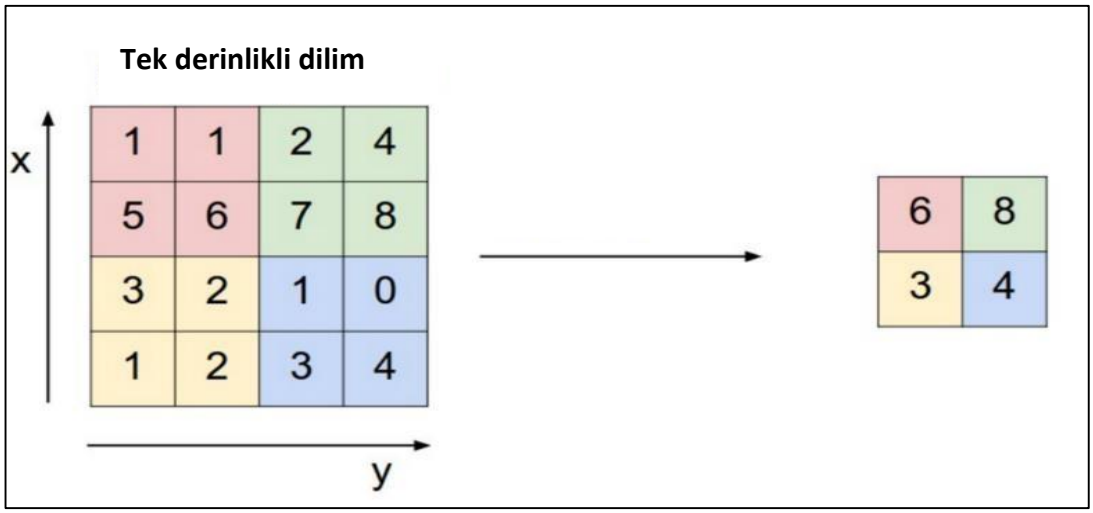

Şekil 3.8 Maksimum havuz filtresi iş başında (Jogin vd., 2018)

Daha sonra, burada uyguladığımız evrişimli sinir ağının mimarisini, kullanılan çeşitli katmanları ve bunlara karşılık gelen hiper parametrelerini ele alacağız. Aşağıdaki Şekil 3.9, modelin evrişim, havuzlama, düzleştirme veya yoğun katman dahil olmak üzere çeşitli katmanlarını göstermektedir.

Evrişim Katmanı 1, Havuzlama Katmanı 1, Evrişim Katmanı 2, Havuz Katmanı 2, Dönüşüm Katmanı 3, Havuz Katmanı 3, Yoğun Katman

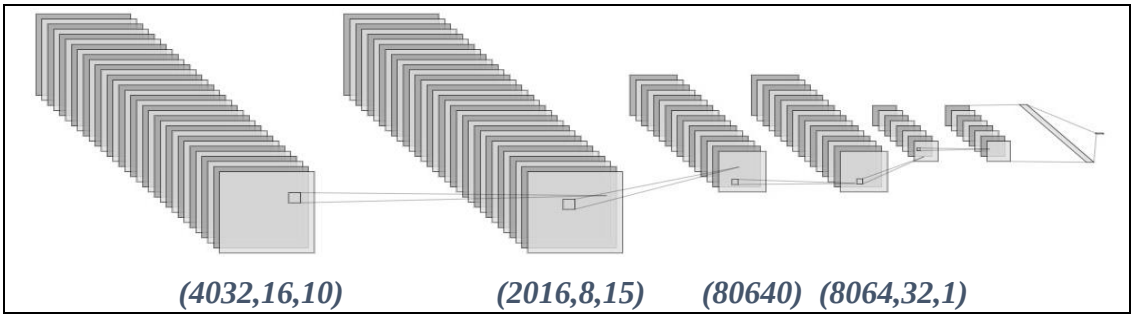

Şekil 3.9 ESA Mimarisi (Lenail, 2020)

3.2.1.4 Modelimizin mimarisi

ESA Modelimiz şunlardan oluşur:

1. Üç Evrişim2D katmanı.

2. Her Evrişim katmanı (5,5) çekirdek boyutunu kullanır.

3. Evrişim katmanlarıyla kullanılan etkinleştirme işlevi DDB'dir.

4. Her evrişim katmanını bir Maksimum Havusu 2D katmanı izler, burada her katmanın durumunda filtre boyutu (2,2)'dir.

5. Maksimum havuz katmanını daha sonra bırakma olasılığı 0,25 ile 0,5 arasında bir bırakma katmanı izler.

6. Yukarıda belirtilen bu katmanları, bir düzleştirme katmanı ve iki yoğun katman izler.

7. Birinci yoğun katman, aktivasyon işlevi olarak DDB'yi kullanırken, başka bir yoğun katman, aktivasyon işlevi olarak Softmax'a sahiptir.

8. Model için kullanılan kayıp fonksiyonu, kategorik çapraz entropi fonksiyonudur.

9. RMSProp, model için optimize edicidir.

4. DENEYSEL SONUÇLAR

Bu tezde, Gabor dalgacık dönüşümü öznitelik çıkarımı için kullanılmıştır (derin öğrenme yüz tanıma için yeni bir yaklaşımdır). Farklı amaçlar için kullanılmak üzere geliştirilmiş, önerilen yüz tanıma sistemi. Ayrıca bu tezde derin öğrenme yüz eğitim verilerinin öznitelik çıkarımı için dalgacık dönüşümünü kullandık, veri seti için ORL veri setini kullandık.

4.1 Özellik Çıkarma Yöntemleri

4.1.1 Gabor Filtresi Kullanarak Özellik Çıkarma

Gabor filtresi, özellikle görüntü tanımada görüntü işlemede çok yardımcı bir araçtır. Uzamsal alandaki iki boyutlu bir Gabor filtresi, aşağıdaki gibi tanımlanan karmaşık bir sinüzoidal düzlem dalgası tarafından modüle edilen bir Gauss çekirdeği fonksiyonudur:

$$G(x,y) = \frac{f^2}{\pi\gamma\eta}\exp\left(-\frac{x^2+\gamma^2 y\prime^2}{2\sigma^2}\right)\exp(j^2\pi x' + \emptyset) \tag{4.1}$$

$x' = xcos\theta + ysin\theta$

$y' = -xsin\theta + ycos\theta$

burada f sinüzoidin frekansını temsil eder, θ normalin bir Gabor fonksiyonunun paralel şeritlerine yönelimi, ϕ faz kaymasıdır, σ Gauss zarfının standart sapmasıdır ve γ Gabor işlevi için eliptik destek uzaysal en boy oranıdır.

Frekans veya (dalga boyu), fonksiyondaki şeritlerin genişliğini yönetir ve frekansı artırarak çizgiler incelir. Yön, Gabor zarfının dönüşünü yönetir, en-boy oranı işlevin yüksekliğini kontrol eder, çok büyük en-boy oranı için, zarf bir piksel yüksekliğe yaklaşır ve çok küçük bir en-boy oranı için, yükseklik görüntü boyunca uzanır. Bant genişliği, büyük bir bant genişliği için Gabor zarfının genel boyutunu kontrol eder, zarf artar ve daha fazla şerit sağlar.

Şekil 4.1 ile 4.3, bir Gabor'un işlevi için bazı parametreleri değiştirmenin etkisini göstermektedir.

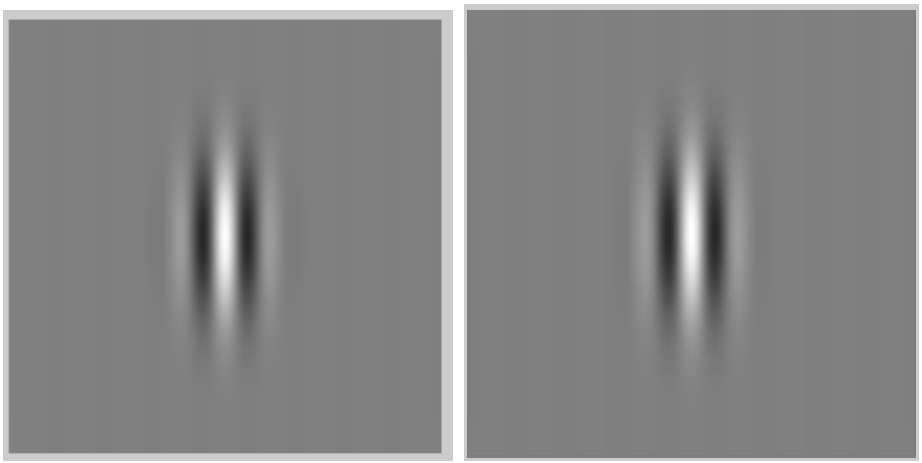

Şekil 4.1 Farklı dalga boyu değerleri (Sol: 25, Sağ: 50).

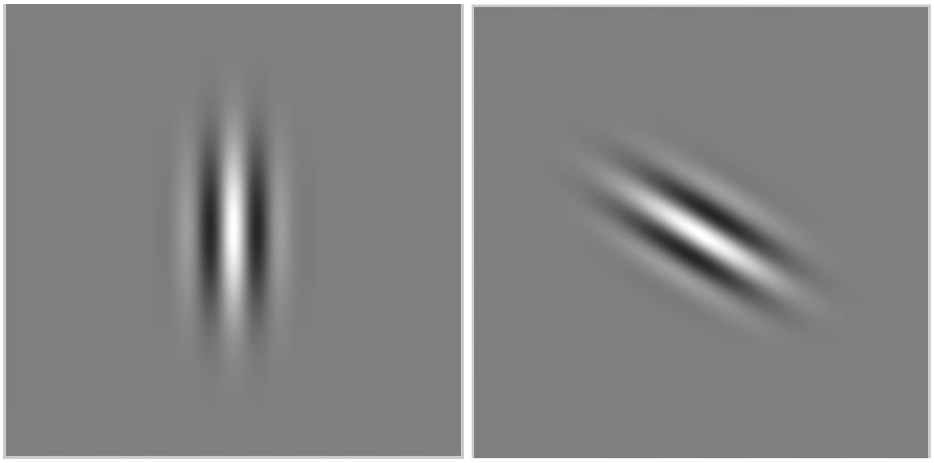

Şekil 4.2 Farklı yönelim (Sol: 0, Sağ: 45).

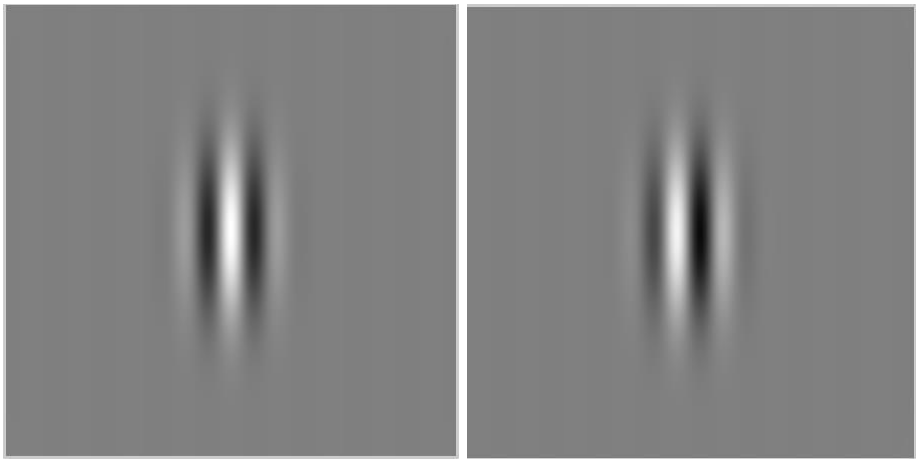

Şekil 4.3 Faz kaydırma değerlerinin değiştirilmesi (Sol: 180, Sağ: 90).

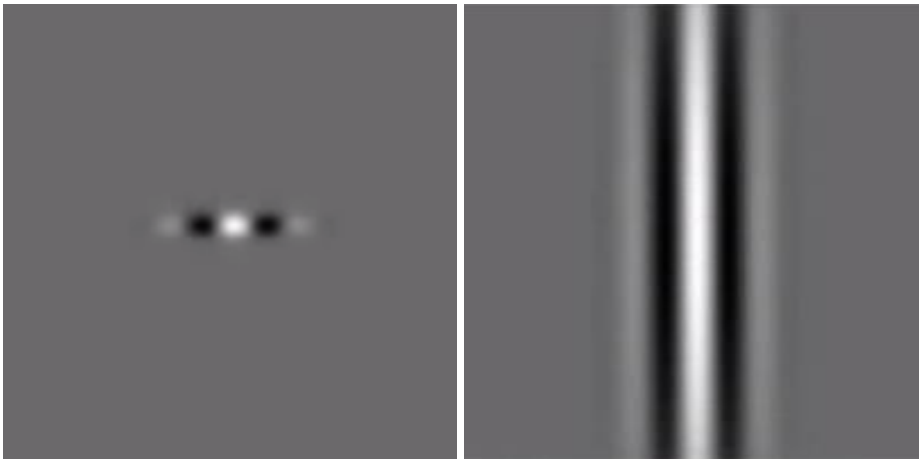

Şekil 4.4 En boy oranı çok büyük (solda) ve çok küçük (sağda).

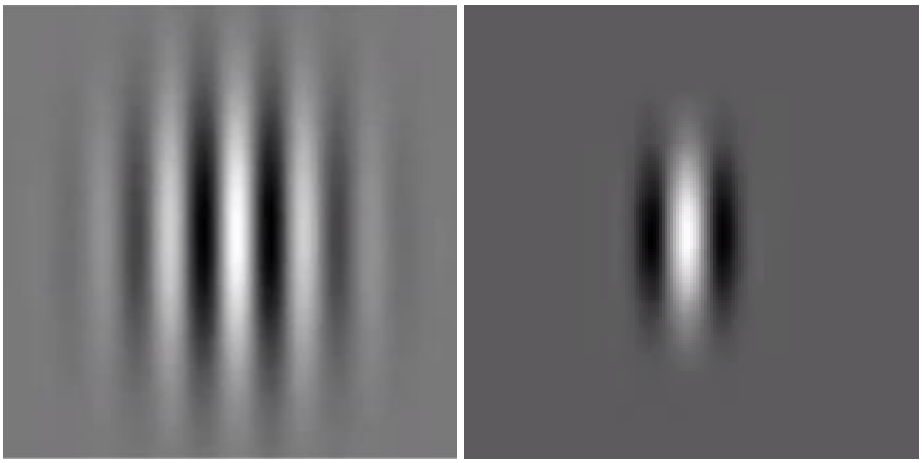

Şekil 4.5 Farklı bant genişliği değerleri (Sol: büyük, Sağ: küçük).

Gabor filtrelerinin birçok avantajı vardır, örneğin dönme, ölçek ve çeviriye değişmezlik, ayrıca aydınlatma değişikliği gibi görüntülerdeki bozulmalara karşı dayanıklıdırlar (Ayad vd., 2019; Valechha vd., 2020) ve doku temsili ve ayrımcılık için özellikle uygun oldukları görülmüştür.

Farklı frekanslara ve yönlere sahip bir dizi Gabor filtresi bir özellikle doku analizi ve segmentasyon için özellik çıkarmada kullanışlıdır. Yönü değiştirerek, belirli bir yöne yönelik dokuyu arayabiliriz. Gauss zarfının standart sapmasını değiştirerek, analiz edilen görüntü belgesinin temeli veya boyutunu değiştiririz.

4.2 ESA Kullanarak Algılama

Bir ESA, bir dizi evrişimli ve alt örneklene katmanından, isteğe bağlı olarak, ardından tamamen bağlı katmanlardan oluşur. Bir evrişimli katmanın girdisi m × m × r görüntüsüdür, burada m, görüntünün yüksekliği ve genişliğidir ve r, kanal sayısıdır, örneğin, bir RGB görüntüsünün r=3 vardır. Evrişim katmanı n × n × q boyutunda k filtreye (veya çekirdeğe) sahip olacaktır; burada n, görüntünün boyutundan daha küçültür ve q, kanal sayısıyla aynı veya daha küçük olabilir ve her çekirdek için değişebilir. Şekil 4.6, bir ESA'nın genel topolojisini gösterir.

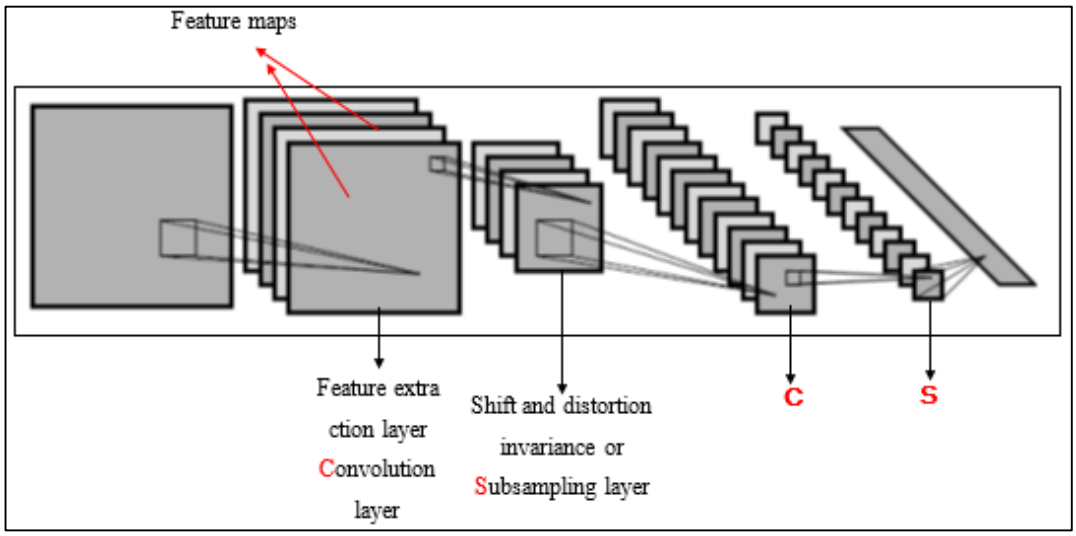

Şekil 4.6 ESA'nın topolojisi.

4.3 Veri Tabanı

Bu çalışmadaki veri tabanı, ORL veri tabanından yapılmıştır.

ORL veri tabanından alınan bazı yüz görüntüleri şekil 4.7.'de gösterilmektedir.

Şekil 4.7 ORL veri tabanı

Derin sinir ağı için, tablo 4'de çoklu denemelerden elde ettiğimiz sonuçları göstermektedir. Buradaki sonuçlar, gizli katman düğümleri, öğrenme hızı, parti boyutu gibi çeşitli parametreler açısından tartışılmıştır. Tüm bu hiper parametreler, farklı yüz görüntüsü testi veri noktaları ve eğitim noktaları ile çeşitlendirilmiştir. Optimum sonuçlar nihai sonuçlar olarak burada sunulmuştur.

Derin sinir ağı sonuçları tablosunda bahsedildiği gibi, %75E yakın bir test doğruluğu üreten hiper parametreler, sırasıyla gizli katman 1 düğüm, gizli katman 2 düğümler, gizli katman 3 düğümler, öğrenme hızı, parti boyutu ve dönem sayısı olan, 5.500, 2.500, 1.500, 0,00001 , 8, 80'dir.

Tablo 4.1 Derin Sinir Ağı Sonuçları

Seri Numarası	Gizli Katman 1 Düğüm	Gizli Katman 2 Düğüm	Gizli Katman 3 Düğüm	Öğrenme Oranı	Parti Boyutu	Dönem	Test Doğruluğu
1	3,000	1,500	1,000	0,0001	5	60	%57,5
2	6,000	3,500	3,000	0,00001	8	80	%67,5
3	5,500	1,500	3,000	0,00001	8	80	%70,0
4	5,500	1,500	2,500	0,00001	8	80	%72,5
5	5,500	2,500	1,500	0,00001	8	80	%77,5

ESA durumunda, sonuçlardaki varyasyon esas olarak çağ sayısı, evrişim çekirdek boyutu ve optimize ediciyi değiştirerek elde edilmiştir. Tablo 4.2, evrişim ağı modeli için çalıştırılan bazı testleri listelemektedir.

Tablo 4.2 Evrişimli Sinir Ağı Sonuçları

Seri No	Evrişim Çekirdek Boyutu	Çekirdek Sayısı	Öğrenme Oranı	Kullanılan Optimizerler	Dönem	Eğitim Doğruluğu	Test Doğruluğu
1	(5,5), (5,5), (5,5)	10,15,20	0,0001	RMSprop	50	%80,08	%55,00
2	(5,5), (5,5), (5,5)	10,15,20	0,0001	RMSProp	100	%92,35	%57,50
3	(5,5), (5,5), (5,5)	10,15,20	0,0001	RMSProp	80	%95,08	%62,5
4	(3,3), (3,3), (3,3)	10,15,20	0,0001	RMSProp	60	%93,87	%50,00
5	(5,5), (5,5), (5,5)	10,15,20	0,0001	Adadelta	90	%82,00	%50,00
6	(5,5), (5,5), (5,5)	10,15,20	0,0001	RMSProp	60	%95,16	%65,00

Bir optimize edici olarak RMSProp, sahip olduğumuz veri kümesi miktarı göz önüne alındığında bazı iyi test doğrulukları üretti. Modeli eğitmek için toplam 400 veri (112*92 çözünürlüklü) kullanılmış ve belirli sayıda dönem için eğitimden sonra modeli test etmek için bir katılımcı verisi dikkate alınmıştır. Yetersiz uyumu önlemek ve aşırı uydurmayı yönetmek için bir dizi dönem değiştirildi. Burada kullandığımız evrişimli katman tabanlı model için 60 ila 70 arasında optimal bir dönem aralığı olduğu kanıtlandı. Çeşitli test çalışmaları, evrişim çekirdek boyutu (5,5) ve çekirdek sayısı katmandan her evrişim katmanı için 10, 15, 20 olarak ayarlandığında yaklaşık %65.00 civarında bir test doğruluğu üretti. Sırasıyla 1 ila 3. Burada kullanılan öğrenme oranı değeri 0,0001 idi. Çeşitli ESA uygulamaları için doğruluk ve dönem grafikleri şekil 4.8.'de gösterilmektedir. Dönem ile eğitim doğruluğunun çeşitliliği:

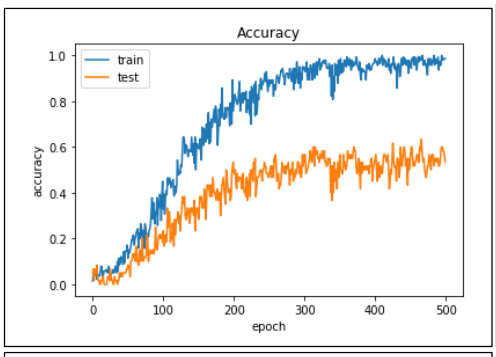

Dönem: 500
Eğitim Doğruluğu: %99.85
Test Doğruluğu: %45.00
çekirdek_boyutu=(3,3)
parti_boyutu = 128

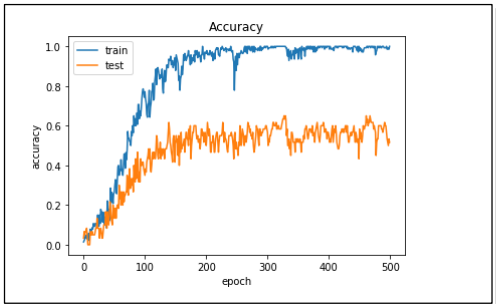

Dönem 500
Eğitim Doğruluğu: % 99.88
Test Doğruluğu: % 55.00
çekirdek_boyutu=(5,5)
parti_boyutu = 64

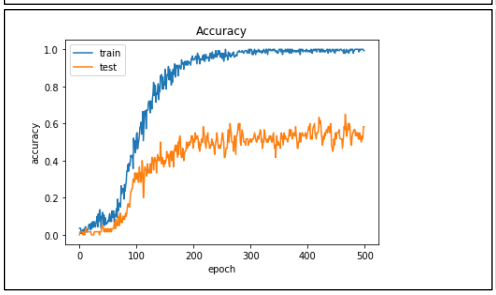

Dönem: 500
Eğitim Doğruluğu: % 99.99
Test Doğruluğu: %59.00
çekirdek_boyutu=(5,5)
parti_boyutu = 248

Şekil 4.8 Çeşitli ESA yürütmeleri için doğruluk ve dönem grafikleri.

4.4 Önerilen Yöntemin Özeti

Önerilen yöntemin özeti Şekil 4.9'da gösterilmektedir.

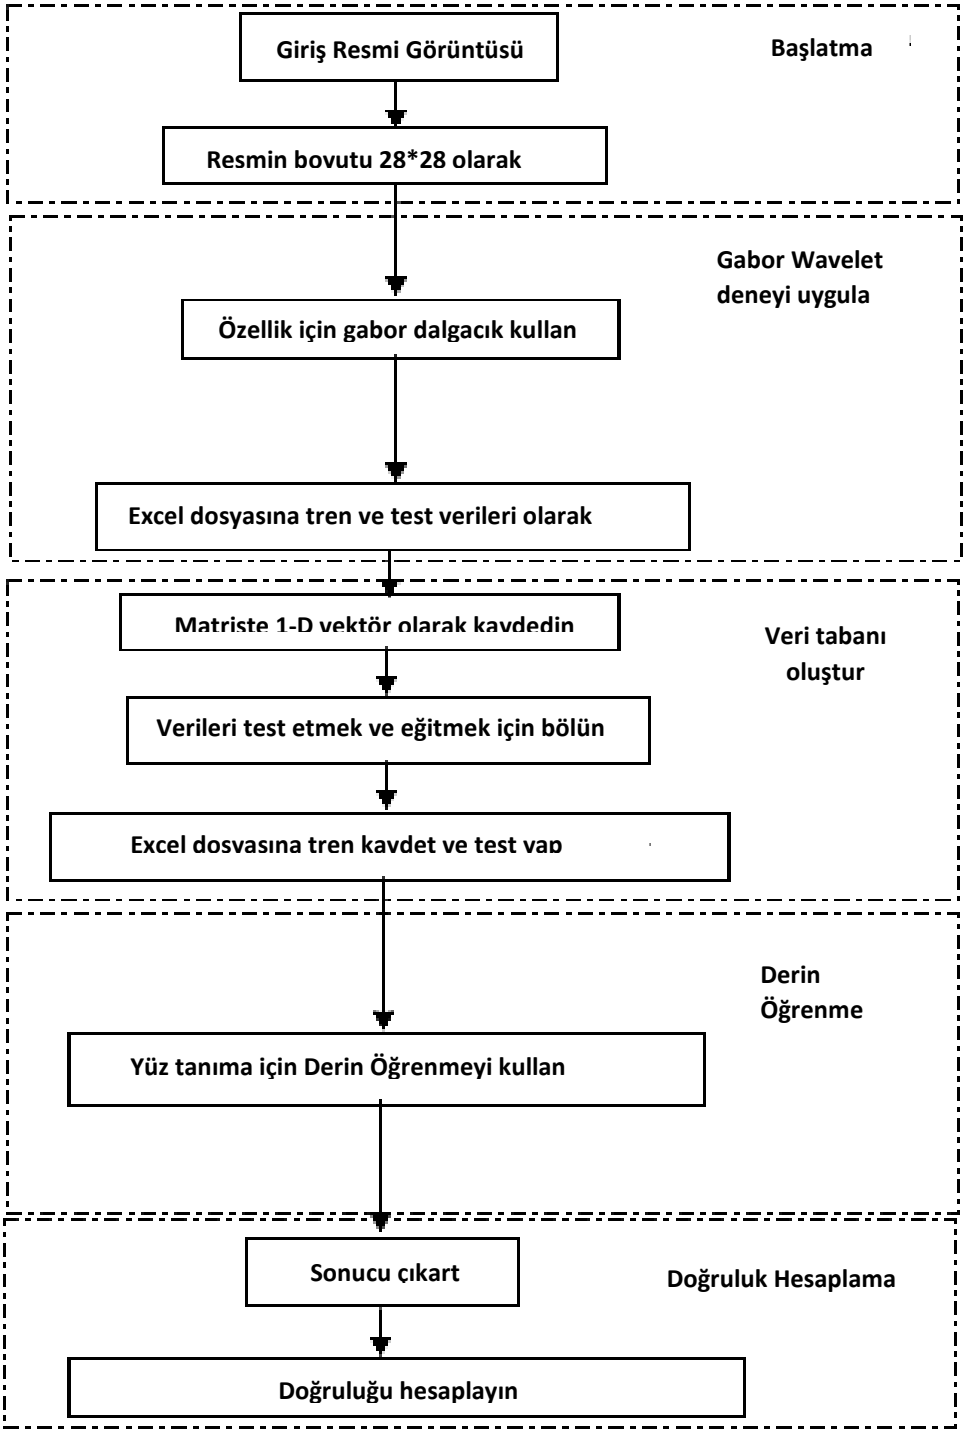

Şekil 4.9 Önerilen yöntemin özeti.

4.5 Kontrol Noktası Tekniğini Kullanma

Bu tezde önerilen yöntemi kontrol noktasıyla ve kontrol noktası olmadan test ettik. Python kodunda kullandığımız "ModelCheckpoint" modeli her dönemden sonra kaydeder. Kontrol noktaları, doğru kullanıldığında Python programcılarına büyük miktarda zaman ve sıkıntıdan tasarruf edilebilen, Defter uygulamasına özgü bir özelliktir. Kontrol noktası, bir tür ara kaydetme ve kaynak kontrolünün tek bir pakette birleştirilmesidir.

Kontrol noktaları, bir model tarafından kullanılan tüm parametrelerin tam değerini yakalar. Kontrol noktaları, model tarafından tanımlanan hesaplamanın herhangi bir açıklamasını içermez ve bu nedenle tipik olarak yalnızca kaydedilen parametre değerlerini kullanacak kaynak kodu mevcut olduğunda yararlıdır.

Python'da kullandığımız program aşağıda gösterilmektedir:

```
# without checkpoint

#history = model.fit(x_train, y_train, validation_data = (x_test, y_test), epochs=epochs, batch_size=batch_size)

# checkpoint

filepath="weights.best.hdf5"

checkpoint = ModelCheckpoint(filepath, monitor='val_accuracy', verbose=1, save_best_only=True, mode='max')

callbacks_list = [checkpoint]

# Fit the model

history = model.fit(x_train, y_train, validation_split=0,33, epochs=150, batch_size=10, callbacks=callbacks_list, verbose=0)
```

Bu kodda gösterildiği gibi, kontrol noktası modeli "ModelCheckpoint(.)" fonksiyonuna ihtiyaç duyar. Ancak programı çalıştırdıktan sonra aşağıdaki sonucu elde ettik (bkz. Şekil 4.10)

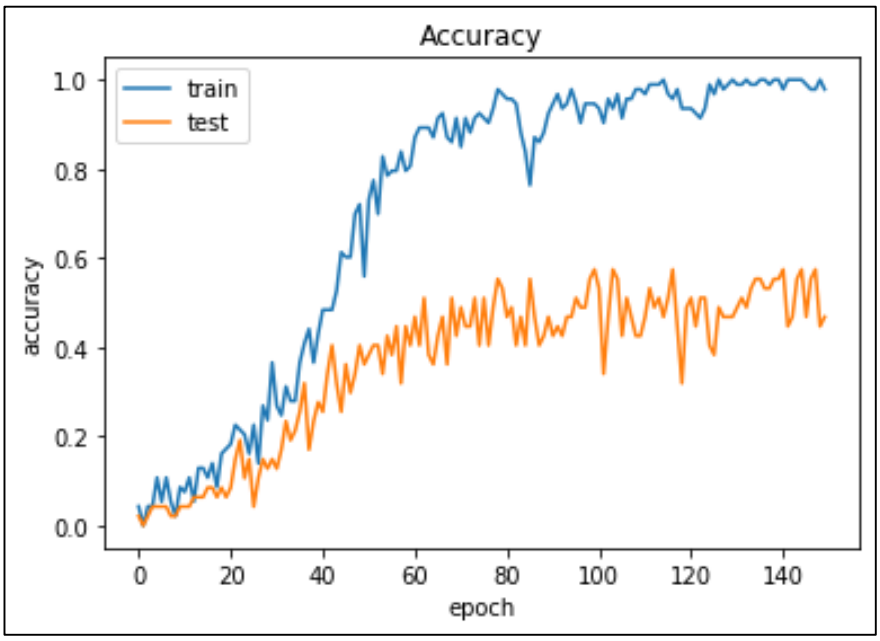

Şekil 4.10 Kontrol noktası tekniği ile sonuç

Ancak kontrol noktası olmayan durumda aşağıdaki sonucu elde ettik (bkz. Şekil 4.11).

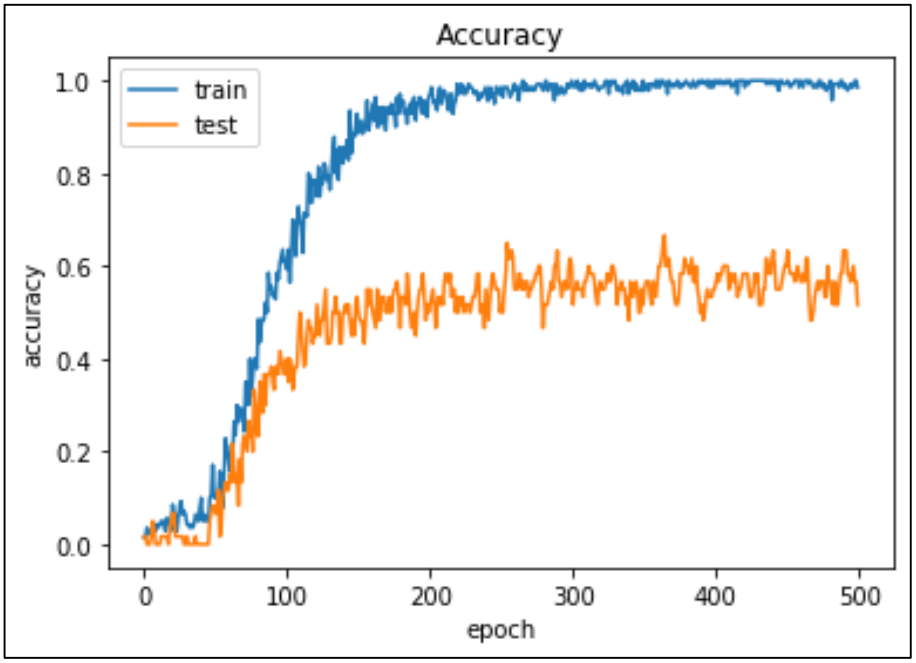

Şekil 4.11 Kontrol noktası tekniği olmadan sonuç

Her iki sonucu karşılaştırırken, kontrol noktası olmayan kontrol noktasıyla olan değerinden daha iyi sonuç verir.

5. SONUÇ

Sağlam ve doğru yüz yanıma (YT), bilgisayarla görme uygulamalarının en pratik sorunlarından biridir. Pratik yüz tanıma uygulamalarında, insan yüzü sınırlı sayıda eğitim görüntüsüne sahip olabilir. Bununla birlikte, genel olarak eğitim görüntülerinin sayısının artmasının da yüz tanıma performansını artırdığı bilinmektedir. Birçok yüz tanıma yöntemi öneriliş olsa da, sağlam yüz tanıma sistemi hala zorlu bir görevdir. Bu çalışmada derin öğrenme sinir ağı kullanılarak tanıma performansı geliştirildi. Bu tez, eğitim sürecinin sınırlılığını aşmanın etkili bir yolunu sunmuştur. Yüzün Gabor özelliklerini kullanarak performans arttırıldı. Görüntü örnekleri, özellikleri ayıklamak için Gabor Dalgacık Dönüşümünde (GDD) kullanılır. Daha sonra bu örneklerin özellikleri evrişimli sinir ağında kullanılır. Bu tez aynı zamanda tanıma sisteminde Gabor dalgacık özellik çıkarımı ve evrişimli sinir ağının kullanılmasının sonuçların iyileştirilmesi üzerinde önemli bir etkisi olduğunu göstermiştir.

KAYNAKLAR

Ahonen, T., Hadid, A., & Pietikäinen, M. (2004). Face recognition with local binary patterns. In *Computer vision-eccv 2004* (pp. 469-481): Springer.

Al-Shiha, A. A. M., Woo, W. L., & Dlay, S. S. (2014). Multi-linear neighborhood preserving projection for face recognition. *Pattern Recognition, 47*(2), 544-555.

Ayad, H., George, L. E., Mohammed, M. J., Hadi, R. A., & Abdullah, S. N. H. S. (2019). An Efficient Approach for Visual Object Categorization based on Enhanced Generalized Gabor Filter and SVM Classifier. *Journal of Engineering and Applied Sciences, 14*(16), 5753-5761.

Banerjee, P. K., & Datta, A. K. (2014). Class specific subspace dependent nonlinear correlation filtering for illumination tolerant face recognition. *Pattern Recognition Letters, 36*, 177-185.

Basri, R., & Jacobs, D. W. (2003). Lambertian reflectance and linear subspaces. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 25*(2), 218-233. Retrieved from http://ieeexplore.ieee.org/ielx5/34/26436/01177153.pdf?tp=&arnumber=1177153&isnumber=26436

Belhumeur, P. N., Hespanha, J. P., & Kriegman, D. J. (1997). Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 19*(7), 711-720. Retrieved from http://ieeexplore.ieee.org/ielx1/34/13123/00598228.pdf?tp=&arnumber=598228&isnumber=13123

Blanz, V., Scherbaum, K., Vetter, T., & Seidel, H. P. (2004). *Exchanging faces in images.* Paper presented at the Computer Graphics Forum.

Blanz, V., & Vetter, T. (2003). Face recognition based on fitting a 3D morphable model. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 25*(9), 1063-1074. Retrieved from http://ieeexplore.ieee.org/ielx5/34/27551/01227983.pdf?tp=&arnumber=1227983&isnumber=27551

Bledsoe, W. (1966). The model method in facial recognition: Technical report PRI-15. *Panoramic Research Inc., Palo Alto*.

Bledsoe, W. W. (1966). Man-machine facial recognition. *Rep. PRi, 22*.

Elgammal, A., & Lee, C.-S. (2004). *Separating style and content on a nonlinear manifold.* Paper presented at the Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on.

Georghiades, A. S., Belhumeur, P. N., & Kriegman, D. J. (2001). From few to many: Illumination cone models for face recognition under variable lighting and pose. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 23*(6), 643-660. Retrieved from http://ieeexplore.ieee.org/ielx5/34/20053/00927464.pdf?tp=&arnumber=927464&isnumber=20053

Givens, G. H., Beveridge, J. R., Phillips, P. J., Draper, B., Lui, Y. M., & Bolme, D. (2013). Introduction to face recognition and evaluation of algorithm performance. *Computational Statistics & Data Analysis, 67*, 236-247.

Gross, R., Matthews, I., & Baker, S. (2002). *Eigen light-fields and face recognition across pose.* Paper presented at the Automatic Face and Gesture Recognition, 2002. Proceedings. Fifth IEEE International Conference on.

Han, J., & Moraga, C. (1995). *The influence of the sigmoid function parameters on the speed of backpropagation learning.* Paper presented at the International Workshop on Artificial Neural Networks.

He, X., Yan, S., Hu, Y., Niyogi, P., & Zhang, H.-J. (2005). Face recognition using Laplacianfaces. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 27*(3), 328-340. Retrieved from http://ieeexplore.ieee.org/ielx5/34/30209/01388260.pdf?tp=&arnumber=1388260&isnumber=30209

Hinton, G., Srivastava, N., & Swersky, K. (2012). Neural networks for machine learning. *Coursera, video lectures, 264*, 1.

Hsieh, P.-C., & Tung, P.-C. (2009). A novel hybrid approach based on sub-pattern technique and whitened PCA for face recognition. *Pattern Recognition, 42*(5), 978-984.

Jogin, M., Madhulika, M., Divya, G., Meghana, R., & Apoorva, S. (2018). *Feature extraction using Convolution Neural Networks (CNN) and Deep Learning.* Paper presented at the 2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT).

Kim, T.-K., & Kittler, J. (2005). Locally linear discriminant analysis for multimodally distributed classes for face recognition with a single model image. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 27*(3), 318-327. Retrieved from http://ieeexplore.ieee.org/ielx5/34/30209/01388259.pdf?tp=&arnumber=1388259&isnumber=30209

Kusuma, G. P., & Chua, C.-S. (2011). PCA-based image recombination for multimodal 2D+ 3D face recognition. *Image and Vision Computing, 29*(5), 306-316.

Lee, H., Grosse, R., Ranganath, R., & Ng, A. Y. (2009). *Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations.*

Paper presented at the Proceedings of the 26th annual international conference on machine learning.

Lenail, A. (2020). NN-SVG: Publication-ready nn-architecture schematics. In.

Li, S., Gong, D., & Yuan, Y. (2013). Face recognition using Weber local descriptors. *Neurocomputing, 122*, 272-283.

Liu, D. (2017). A practical guide to relu. *Retrieved from medium. com.(Nov. 2017): https://medium. com/tinymind/a-practical-guide-to-relu-b83ca804f1f7*.

Liu, Z., Pu, J., Wu, Q., & Zhao, X. (2016). Using the original and symmetrical face training samples to perform collaborative representation for face recognition. *Optik-International Journal for Light and Electron Optics, 127*(4), 1900-1904.

Lu, Z., & Zhang, L. (2016). Face recognition algorithm based on discriminative dictionary learning and sparse representation. *Neurocomputing, 174*, 749-755.

Luan, X., Fang, B., Liu, L., & Zhou, L. (2013). Face recognition with contiguous occlusion using linear regression and level set method. *Neurocomputing, 122*, 386-397.

Luh, G.-C., & Lin, C.-Y. (2011). PCA based immune networks for human face recognition. *Applied soft computing, 11*(2), 1743-1752.

Mairal, J., Ponce, J., Sapiro, G., Zisserman, A., & Bach, F. R. (2009). *Supervised dictionary learning.* Paper presented at the Advances in neural information processing systems.

Moghaddam, F. B., & Zand, M. (2019). An overview of face recognition based on eye iris. *Artigence, 1*(1).

Nair, V., & Hinton, G. E. (2010). *Rectified linear units improve restricted boltzmann machines.* Paper presented at the Proceedings of the 27th international conference on machine learning (ICML-10).

Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.

Oh, S.-K., Yoo, S.-H., & Pedrycz, W. (2013). Design of face recognition algorithm using PCA-LDA combined for hybrid data pre-processing and polynomial-based RBF neural networks: Design and its application. *Expert Systems with Applications, 40*(5), 1451-1466.

Pentland, A., Moghaddam, B., & Starner, T. (1994). *View-based and modular eigenspaces for face recognition.* Paper presented at the Computer Vision and Pattern Recognition, 1994. Proceedings CVPR'94., 1994 IEEE Computer Society Conference on.

Prince, S. J., Warrell, J., Elder, J. H., & Felisberti, F. M. (2008). Tied factor analysis for face recognition across large pose differences. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 30*(6), 970-984. Retrieved from http://ieeexplore.ieee.org/ielx5/34/4492939/04459336.pdf?tp=&arnumber=4459336&isnumber=4492939

Ramamoorthi, R. (2002). Analytic PCA construction for theoretical analysis of lighting variability in images of a Lambertian object. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 24*(10), 1322-1333. Retrieved from http://ieeexplore.ieee.org/ielx5/34/22272/01039204.pdf?tp=&arnumber=1039204&isnumber=22272

RASOOL, M. M. R. (2019). *FACE RECOGNITION USING LBP, nLBP and αLBP ALGORITHMS.* SİİRT ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ,

Roell, J. (2017). From Fiction to Reality: A Beginner's Guide to Artificial Neural Networks. In: Accessed 2019-06-20.

Samaria, F. S., & Harter, A. C. (1994). *Parameterisation of a stochastic model for human face identification.* Paper presented at the Proceedings of 1994 IEEE workshop on applications of computer vision.

Shashua, A., & Riklin-Raviv, T. (2001). The quotient image: Class-based re-rendering and recognition with varying illuminations. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 23*(2), 129-139. Retrieved from http://ieeexplore.ieee.org/ielx5/34/19622/00908964.pdf?tp=&arnumber=908964&isnumber=19622

Shin, D., Lee, H.-S., & Kim, D. (2008). Illumination-robust face recognition using ridge regressive bilinear models. *Pattern Recognition Letters, 29*(1), 49-58. Retrieved from http://ac.els-cdn.com/S016786550700267X/1-s2.0-S016786550700267X-main.pdf?_tid=847276d4-cf34-11e5-b5bf-00000aacb35e&acdnat=1455026197_b997def84da745ce5ffeae3740839a7a

Tan, K., & Chen, S. (2005). Adaptively weighted sub-pattern PCA for face recognition. *Neurocomputing, 64*, 505-511.

Tenenbaum, J. B., & Freeman, W. T. (2000). Separating style and content with bilinear models. *Neural computation, 12*(6), 1247-1283. Retrieved from http://www.mitpressjournals.org/doi/abs/10.1162/089976600300015349

Tripathi, S., Acharya, S., Sharma, R. D., Mittal, S., & Bhattacharya, S. (2017). *Using Deep and Convolutional Neural Networks for Accurate Emotion Classification on DEAP Dataset.* Paper presented at the Twenty-Ninth IAAI Conference.

Turk, M. A., & Pentland, A. P. (1991). *Face recognition using eigenfaces.* Paper presented at the Computer Vision and Pattern Recognition, 1991. Proceedings CVPR'91., IEEE Computer Society Conference on.

Valechha, L., Valecha, H., Ahuja, V., Chawla, T., & Sengupta, S. (2020). Orisyncrasy—An Ear Biometrics on the Fly Using Gabor Filter. In *Advances in Data Sciences, Security and Applications* (pp. 457-466): Springer.

Vasilescu, M. A. O., & Terzopoulos, D. (2003). *Multilinear subspace analysis of image ensembles.* Paper presented at the Computer Vision and Pattern Recognition, 2003. Proceedings. 2003 IEEE Computer Society Conference on.

Wang, H., Leng, Y., Wang, Z., & Wu, X. (2007). Application of image correction and bit-plane fusion in generalized PCA based face recognition. *Pattern Recognition Letters, 28*(16), 2352-2358.

Wang, R., Shan, S., Chen, X., & Gao, W. (2008). *Manifold-manifold distance with application to face recognition based on image set.* Paper presented at the Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on.

Wiskott, L., Fellous, J.-M., Kuiger, N., & Von Der Malsburg, C. (1997). Face recognition by elastic bunch graph matching. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 19*(7), 775-779. Retrieved from http://ieeexplore.ieee.org/ielx1/34/13123/00598235.pdf?tp=&arnumber=598235&isnumber=13123

Yang, M., & Zhang, L. (2010). Gabor feature based sparse representation for face recognition with gabor occlusion dictionary. In *Computer Vision–ECCV 2010* (pp. 448-461): Springer.

Zhang, D., & Zhou, Z.-H. (2005). (2D) 2PCA: Two-directional two-dimensional PCA for efficient face representation and recognition. *Neurocomputing, 69*(1), 224-231.

Zhang, L., & Samaras, D. (2006). Face recognition from a single training image under arbitrary unknown lighting using spherical harmonics. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, 28*(3), 351-363. Retrieved from http://ieeexplore.ieee.org/ielx5/34/33380/01580481.pdf?tp=&arnumber=1580481&isnumber=33380

Zhao, W., Chellappa, R., Phillips, P. J., & Rosenfeld, A. (2003). Face recognition: A literature survey. *ACM computing surveys (CSUR), 35*(4), 399-458. Retrieved from http://dl.acm.org/citation.cfm?doid=954339.954342

Zhou, C., Wang, L., Zhang, Q., & Wei, X. (2013). Face recognition based on PCA image reconstruction and LDA. *Optik-International Journal for Light and Electron Optics, 124*(22), 5599-5603.

Zhou, S., & Chellappa, R. (2003). *Rank constrained recognition under unknown illuminations.* Paper presented at the Analysis and Modeling of Faces and Gestures, 2003. AMFG 2003. IEEE International Workshop on.

Zhou, S. K., & Chellappa, R. (2004). *Illuminating light field: Image-based face recognition across illuminations and poses.* Paper presented at the Automatic

Face and Gesture Recognition, 2004. Proceedings. Sixth IEEE International Conference on.