

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



YÜZ TANIMA TEKNİĞİNE DAYALI YOKLAMA SİSTEMİ
GELİŞTİRİLMESİ

AHMED B SALEM SALAMH

DOKTORA TEZİ

DOÇ. DR. HALİL İBRAHİM AKYÜZ

MART - 2023
KASTAMONU

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.

Ahmed B Salem SALAMH

ÖZET

DOKTORA TEZİ

YÜZ TANIMA TEKNİĞİNE DAYALI YOKLAMA SİSTEMİ GELİŞTİRİLMESİ

AHMED B SALEM SALAMH

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: DOÇ. DR. HALİL İBRAHİM AKYÜZ

Yüz tanıma, insan yüzlerini tanımak için yaygın olarak kullanılan biyometrik teknolojilerden biridir. Yüz tanıma sistemleri, yüzün biyolojik özelliklerinin değişmez olması ve yüz tanımanın kolay uygulanabilirliği gibi bir takım avantajlarının bir sonucu olarak daha popüler hale gelmiştir. Sonuç olarak, uzaktan eğitim, güvenlik ve sosyal medya dahil olmak üzere çeşitli uygulamalarda genellikle en etkili biyometrik teknoloji olarak kabul edilmektedir. Bununla birlikte, tamamen güvenli, doğru ve güvenilir yüz tanıma yapabilmenin önünde hala aşılması gereken bazı engeller bulunmaktadır. Uzaktan eğitimde, yüz öznitelik çıkarımı, katılımcıların konumlarını değiştirmelerini engellediği için görünüş geçerliliğini korumak için yararlıdır. Ancak, yüz tanımanın çeşitli alanlarında araştırma ve pratik uygulamalar arasında bir boşluk vardır. Ayrıca, uzaktan eğitime olan talep önemli ölçüde artmıştır. Bu artış, izolasyon ve sosyal mesafe gibi zorunlu koşulların getirdiği çeşitli engellerden kaynaklanmaktadır ve bu alanda yüz tanıma tekniklerinin kullanılması, öğrenme sürecini geliştirmek için faydalı olmaktadır. Bu tez, yüz tanıma sistemlerinde ortaya çıkan ışıklandırma değişimi, poz değişimi ve oklüzyon gibi önemli sorunları araştırmaktadır. Bu problemleri çözmek için birçok teknik ve algoritma önerilmiştir. Bu tez, yeni bir yüz tanıma tekniğine dayalı bir uzaktan eğitim yoklama modeli sunmaktadır. Bu doğrultuda yüz öznitelik çıkarımı yapabilen ve yüz tanıma karşılaşılan zorlukları çözebilen iki yeni teknik geliştirilmiştir. Çoklu tanımlayıcı adı verilen ilk yeni model, iyi bilinen yerel ikili örüntü yöntemine dayanmaktadır. Bu model merkez pikselin çok sayıda farklı komşusunu ele almaktadır. Modelin özgün avantajı, bu tanımlayıcının sadece bir nokta yerine farklı komşuluk boyutlarının kullanılmasına izin vermesidir. Bu yapı, makul bir etkinlik seviyesine erişmekte ve ayrıca farklı bir öznitelik dağılımı elde etme imkanı sağlamaktadır. Bu çalışmada önerilen tanımlayıcıya dayalı ikili öznitelik tanımlayıcı kullanan başka bir yüz tanıma modeli geliştirilmiş ve iki model arasındaki benzerlik ve farklılıkları araştırmak için yerel ikili örüntüler oluşturulmuştur. Her iki model için de kamera mesafesi, ifade, büyük kafa boyutu ve ışıklandırma değişikliği gibi yüz tanıma sorunlarının üstesinden gelmek için farklı yüz veri tabanlarında destek vektör makinesi yöntemi kullanılarak eğitim yapılmıştır. Ek olarak, derin öğrenmeyi kullanarak, yüz tanımayı geliştirmek için yeni ama oldukça verimli bir evrimsel sinir ağı olan In-depth yöntemi sunulmaktadır. Bu yöntem, sıralı ve artık kimlik bloklarının bir kombinasyonuna dayanmaktadır. Bu yöntem kullanıldığında, daha derin bloklar kullanmanın etkililiği araştırılabilmektedir. Bu çalışmada yeni modelin, diğer son teknoloji yöntemlerle karşılaştırıldığında, yüz öznitelik çıkarımını yüksek doğruluk oranıyla gerçekleştirebildiği kanıtlanmıştır. Uzaktan eğitim yoklama sürecinde, eğitim verilerinin sınırlılığı, yüz tanıma ve doğrulama ile ilgili çeşitli zorluklarla karşılaşılmaktadır. Bu

alıřmada uzaktan eđitim bađlamında yz tanıma ve yoklama iin yeni bir mimari sunulmaktadır. Bu modelin avantajlarından biri, nerilen model ve destek vektr makinesi kullanılarak ıkarılan znitelik ıkarımı ve eđitim yapılmasıdır. Bu yntem, tanıma ve yoklama hatalarını azaltmaktadır. Deneyler, modelimizin ve yoklama modelimizin neredeyse tm yzleri tanıyabildiđini ve bu yzlere karřılık gelen etiketleri kaydedebildiđini gstermiřtir. Bu yeni yz tanıma ve yoklama modeli, uzaktan đrenmeyi daha gvenli, dođru ve gvenilir hale getirerek đretim etkinliđini artırarak uzaktan đrenmenin yaygınlařmasına katkıda bulunabilir

ANAHTAR KELİMELEER: Yz Tanıma, Bilgisayarlı Gr, Derin đrenme, Yapay Zeka, Denetimli makine đrenimi, Uzaktan eđitim

Mart 2023, 125 Sayfa



ABSTRACT

PH.D THESIS

DEVELOPMENT OF AN ATTENDANCE REGISTRATION SYSTEM BASED ON FACE RECOGNITION TECHNIQUE

AHMED B SALEM SALAMH

**KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF MATERIALS SCIENCE AND ENGINEERING
SUPERVISOR: ASSOC. PROF. DR. HALİL İBRAHİM AKYÜZ**

Face recognition is one of the biometric technologies commonly used to identify human faces. Face recognition systems have become more popular as a result of a number of benefits, including the fact that facial biological features are immutable and because they are simple to apply. As a result, it is often recognized as the most effective biometric technology in a variety of applications, including distance learning, security, and social networking. However, there is still a long way to go as there are obstacles that need to be overcome to create secure, accurate, and reliable face recognition. In distance learning, facial feature extraction is useful for maintaining face validity since it prevents participants' positions from changing. However, there is a gap between research and practical applications in various fields of face recognition. In addition, the demand for distance learning has increased drastically. This increase is due to various learning obstacles that arise from enforced conditions such as seclusion and social distancing, and the use of face recognition techniques in this area offers further advantages to enhance the learning process. This thesis explores significant problems that arise in face recognition systems, such as pose and illumination variations, and occlusion. To solve these problems, many techniques and algorithms have been proposed. This thesis presents a distance learning registration model based on a new face recognition technique. We have developed two new techniques capable of extracting facial features and addressing the challenges associated with face recognition. The first new model, called multi-descriptor, is based on the well-known method of local binary patterns. It involves many different neighbourhoods of the central pixel. Its unique advantage is that this descriptor allows the use of different neighborhood sizes instead of only one point. This structure ensures reasonable effectiveness and also provides the possibility to obtain a different distribution of features. A face recognition model using the pairwise feature descriptor based on the proposed descriptor was developed in this work, and local binary patterns were created to investigate the similarity and dissimilarity between the two models. For both models, the training was done using the support vector machine method on different face databases to overcome face recognition problems such as camera distance, expression, large head size, and illumination variations. In addition, using deep learning, we present a novel but highly efficient convolutional neural network for improving face recognition, namely In-depth. The technique is based on a combination of sequential and residual identity blocks. This allows us to evaluate the effectiveness of using deeper blocks. The new model has proven to be able to extract features from faces in a highly accurate manner compared to the other state-of-the-art methods. In the distance learning registration process, there are several challenges related to training data limitation, face

recognition, and verification. We present a new architecture for face recognition and registration in the case of distance learning. One of the advantages of this model is the features extracted and trained using the proposed model and support vector machine. This immediately lowers the recognition and registration errors. The experiments have shown that our model and the registration model are able to recognize almost all the faces and register the corresponding labels. A new face recognition and registration model makes distance learning more secure, accurate, and reliable, enhancing teaching efficacy and boosting distance learning growth

KEYWORDS: Face Recognition, Computer Vision, Deep Learning, Artificial Intelligence, Supervised machine learning, Distance learning

March 2023, 125 Page



TEŞEKKÜR

Kastamonu Üniversitesi'nde öğrenim gördüğüm yıllar boyunca hayatımı hem kişisel hem de akademik olarak etkileyen birçok insan tanıdım. Doktora çalışmalarım sırasındaki yardımlarından dolayı onlara içtenlikle teşekkür etmek istiyorum. En derin şükranlarımı benim için kusursuz bir danışman ve samimi bir arkadaş olan Doç. Dr. Halil İbrahim Akyüz'e sunmak isterim. Kendisi beni akademisyenliğe teşvik etmiş ve bana nasıl bilimsel araştırma yapılacağını en başından başlayarak öğretmiştir. Danışmanım olarak bana her zaman tavsiyelerde bulunmuş ve benim ilham kaynağım olmuştur. Konuşmalarımız ve yaptığı rehberlik benim için çok faydalı olmuştur. Onun bilgece tavsiyeleri, dikkatle koruduğu standartları, nazik yol göstericiliği ve ısrarlı motivasyonu olmadan, prestijli dergilerde bilimsel araştırmalarımı yayınlama imkanı bulamazdım. Ayrıca, doktora çalışmamın son yılındaki profesyonel desteği ve verdiği bilgiler için kendisine çok teşekkür ederim.

Doktora çalışmalarım boyunca sonsuz desteklerini esirgemeyen eşime, kardeşlerime ve özellikle anne ve babama teşekkür ederim. Bu tez onlara ithaf edilmiştir.

AHMED B SALEM SALAMH

Kastamonu, 2023

İÇİNDEKİLER

Sayfa

TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET.....	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xiv
SİMGELER VE KISALTMALAR DİZİNİ	xv
1. GİRİŞ.....	1
1.1 Bağlam.....	1
1.2 Yüz Tanıma ve Yoklama Problemleri.....	5
1.3 Çalışmanın Amacı	6
1.4 Çalışmanın Önemi	7
1.5 Tezin Yapısı	8
2. LİTERATÜR TARAMASI	11
2.1 Yüz Tanımada Yerel Tanımlayıcı Tabanlı Yöntemler.....	17
2.2 Yerel Tanımlayıcı ile İlgili Çalışmalar.....	20
2.3 Yüz Tanımada Derin Öğrenme Tabanlı Yöntemler	23
2.4 Derin Öğrenme İle İlgili Çalışmalar.....	27
2.5 Yüz Tanıma ve Yoklama ile İlgili Çalışmalar.....	32
3. KAVRAMSAL ÇERÇEVE	35
3.1 Yüz Tanımada Derin Evrişimsel Sinir Ağları	35
3.1.1 Derin Öğrenmenin Tarihsel Özeti.....	36
3.2 Evrişimsel Sinir Ağı Mimarisi	37
3.2.1 Evrişim Katmanı ve Öznitelik Çıkarımı	38
3.2.2 Etkinleştirme Fonksiyonu	39
3.2.3 Ortaklama Katmanı.....	40
3.2.4 Tam Bağlı Katman.....	41
3.2.5 Sınıflandırma Katmanı.....	41
3.3 Yüz Tanıma ve Yoklama.....	42
3.3.1 SVM ve Softmax Mimarisi.....	43
3.3.2 SVM Değeri ve SVM Kaybı.....	44
3.3.3 Softmax Değeri ve Softmax Kaybı.....	44
4. METOD ve MATERYAL.....	46
4.1 Tezin Yöntemi	46
4.1.1 Yüz Tanıma Veri Tabanları	49
4.1.2 Face94 Veri Tabanı.....	50
4.1.3 Face95 Veri Tabanı.....	50
4.1.4 Face96 Veri Tabanı.....	51
4.1.5 Grimace Veri Tabanı	52
4.1.6 Yale Veri Tabanı.....	53
4.1.7 Genişletilmiş Yale B Veri Tabanı.....	54
4.1.8 Yüz Tanıma Veri Tabanları	54

4.2	Yüz Tanımadaki Yeni Bir Öznelik Çıkarım Modeli	55
4.3	Karekök Denklemi	57
4.4	Önerilen Yüz Tanıma Yöntemi	60
4.4.1	Teorinin Çıkarımının İspatı	60
4.4.2	Destek Vektör Makinesi	67
4.4.3	Çoklu Tanımlayıcı Öznelik Çıkarım Modeli.....	68
4.5	Verimli Bir Evrişimsel Sinir Ağı Mimarisi	72
4.6	Yüz Tanıma İçin Önerilen Derin Öğrenme Modeli	74
4.7	Uzaktan Eğitim Veri Setleri	76
4.7.1	Veri Çoğaltma	76
4.7.2	Yüz Tanıma ve Uzaktan Yoklama Modeli	79
4.8	Yüz Tanıma Performansının Değerlendirilmesi.....	81
5.	BULGULAR ve YORUM	84
5.1	Çoklu Tanımlayıcı Modeli İle İlgili Bulgular	84
5.1.1	Yale Veri Tabanı Üzerinde Performans Değerlendirme.....	84
5.1.2	Genişletilmiş Yale B Üzerinde Performans Değerlendirme	85
5.1.3	Face94 Veritabanı Üzerinde Performans Değerlendirme	87
5.1.4	Face95 Veritabanı Üzerinde Performans Değerlendirme	88
5.1.5	Face96 Veritabanı Üzerinde Performans Değerlendirme	89
5.1.6	Grimace Veritabanı Üzerinde Performans Değerlendirme.....	90
5.1.7	MD Modellerinin Performans Değerlendirmesi ve Karşılaştırması	91
5.2	Verimli Bir Evrişimsel Sinir Ağı ile ilgili Bulgular	96
5.3	Derin Öğrenme Modeli ile ilgili Bulguları.....	97
5.4	Yüz Tanıma ve Uzaktan Yoklama Modeli ile ilgili Bulgular	101
6.	SONUÇLAR ve ÖNERİLER	107
	KAYNAKLAR	110
	ÖZGEÇMİŞ.....	125

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1 Tezin yapısı.....	8
Şekil 2.1 Yerel ikili örüntü yöntemi.....	17
Şekil 2.2 Farklı ifadeler taşıyan yüzlerde eşleşen öznitelikler ve örnek fotoğraflardaki SIFT özellikleri	19
Şekil 2.3 YGH yapısı ile yüz tanıma.....	20
Şekil 2.4 Derin öğrenmenin performansı	24
Şekil 2.5 Derin öğrenme VGG- yüz tanıma modeli.....	26
Şekil 2.6 ResNet, a) orijinal artık yapı b) ön-aktivasyonlu artık yapı.....	26
Şekil 2.7 Derin öğrenme VGG16 yüz mimarisi.....	28
Şekil 2.8 (a) Orijinal artıksal modül (b) Ön-aktivasyon kullanan artıksal modül.....	30
Şekil 2.9 34 parametrelili bir katmanlı artık ağ.....	30
Şekil 2.10 Herhangi iki katman arasında doğrudan bağlantı kuran bir yoğun ağ.....	31
Şekil 2.11 Yüz tanımanın başarıyla uygulanabilmesi için temel durumlar.	34
Şekil 3.1 Derin sinir ağlarının ana yapısı	37
Şekil 3.2 İleri geçişli ileri beslemeli sinir ağı.....	38
Şekil 3.3 Girdi resminin derinliği, genişliği ve yüksekliği	39
Şekil 3.4 ReLU etkinleştirme fonksiyonu.....	40
Şekil 3.5 Ortalama ortaklama ve maksimum ortaklama yapısı.....	40
Şekil 3.6 Tam bağlı katman yapısı.....	41
Şekil 3.7 Temel evrimsel sinir ağı bloğu.....	42
Şekil 3.8 SVM ve Softmax çıktı sınıflandırma sonuçları	45
Şekil 4.1 Aynı bireye ait bazı örnekler.....	50
Şekil 4.2 Aynı insana ait farklı baş ve ışıklandırma durumları içeren görüntüler	51
Şekil 4.3 Face 96 veritabanından aynı bireye ait farklı yüz görüntüleri	52
Şekil 4.4 Grimace veri tabanından aynı kişiye ait bazı yüz görüntüleri	52
Şekil 4.5 Yale yüz veri tabanından iki farklı kişiye ait yüz görüntüleri	53
Şekil 4.6 Genişletilmiş Yale B veritabanından aynı kişiye ait bazı örnekler.....	54
Şekil 4.7 Karekök hesaplama aşamaları.....	59
Şekil 4.8 Farklı P değerlerinin etkisi.....	59
Şekil 4.9 Tanımlayıcının farklı dağılımlara sahip çoklu yapıları.....	64
Şekil 4.10 Yüz görüntüsünde farklı komşular kullanmanın etkisi.....	64
Şekil 4.11 Genişletilmiş Yale B'den farklı ışıklandırma koşullarına ve aynı bireye ait bazı örnekler.....	65
Şekil 4.12 Genişletilmiş Yale B'den MD1 modeliyle üretilen örnekler.....	65
Şekil 4.13 Genişletilmiş Yale B'den MD2 modeliyle üretilen örnekler.....	66
Şekil 4.14 Öznitelik vektörü boyutluluğu a) MD modeli, b) LBP modeli.....	66
Şekil 4.15 Farklı örnekler için öznitelik vektörü boyutluluğu a) MD modeli, b) MD modeli.	67
Şekil 4.16 İki boyutlu uzay, SVM ayrılması.....	68
Şekil 4.17 Çoklu tanımlayıcı model kullanılarak öznitelik çıkarımının mimarisi	69
Şekil 4.18 Çift yerel ikili örüntü kullanılarak öznitelik çıkarımı	70
Şekil 4.19 Çoklu tanımlayıcı model kullanılarak yüz algılama mimarisi.....	71
Şekil 4.20 Yerel ikili örüntü kullanılarak yüz algılama mimarisi.....	71
Şekil 4.21 Dört evrimsel sinir ağı yapısı	72

Şekil 4.22 Önerilen modelin gösterimi	73
Şekil 4.23 Indepthnet19 öğrenme yapısı, a) ağın ana bileşeni olarak önerilen normal blok, b) bloğa dayalı daha derin ağ için genişletilmiş	75
Şekil 4.24 Ağ için normal blok ve Indepthnet19 yapılandırma bloku	75
Şekil 4.25 Uzay dönüşümü ve döndürme yöntemleri kullanılarak yüz tanıma için çoğaltmanın uygulanması.....	78
Şekil 4.26 Önerilen ESA ve DVM eğitim ve test mimarisi	79
Şekil 4.27 Çevrimiçi yüz yoklama sisteminin bütün mimarisi	81
Şekil 5.1 Çoklu tanımlayıcı modelin Yale veritabanındaki yüz tanıma performansı.....	84
Şekil 5.2 Çift yerel ikili örüntünün Yale veritabanındaki yüz tanıma performansı.....	85
Şekil 5.3 Çoklu tanımlayıcı modelin Genişletilmiş Yale B veritabanındaki yüz tanıma performansı.....	86
Şekil 5.4 Genişletilmiş Yale B için Aydınlatma değişikliklerindeki performansı gösteren ROC eğrisi	86
Şekil 5.5 Çift yerel ikili örüntünün Genişletilmiş Yale B veritabanındaki yüz tanıma performansı.....	87
Şekil 5.6 Çoklu tanımlayıcı modelin Face 94 veritabanındaki yüz tanıma performansı.....	88
Şekil 5.7 Çift yerel ikili örüntünün Face 94 veritabanındaki yüz tanıma performansı.....	88
Şekil 5.8 Çoklu tanımlayıcı modelin Face 95 veritabanındaki yüz tanıma performansı.....	89
Şekil 5.9 Çift yerel ikili örüntünün Face 95 veritabanındaki yüz tanıma performansı.....	89
Şekil 5.10 Çoklu tanımlayıcı modelin Face 96 veritabanındaki yüz tanıma performansı.....	90
Şekil 5.11 Çift yerel ikili örüntünün Face 96 veritabanındaki yüz tanıma performansı.....	90
Şekil 5.12 Çoklu tanımlayıcı modelin Grimace veritabanındaki yüz tanıma performansı.....	91
Şekil 5.13 Çift yerel ikili örüntünün Grimace veritabanındaki yüz tanıma performansı.....	91
Şekil 5.14 Farklı özelliklere sahip farklı veri tabanlarına ait hatırlama, kesinlik ve F1 değerlerinin özeti.....	93
Şekil 5.15 Yeni yüz tanıma modellerinin performanslarının karşılaştırması.....	93
Şekil 5.16 Veri setleri için eğitim ve doğrulama doğruluk eğrileri	96
Şekil 5.17 Veri setleri için ROC eğrileri ve AUC.....	97
Şekil 5.18 Indepthnet19 için çeşitli veri tabanlarındaki eğitim ve doğrulama doğruluğu, eğitim kaybı ve doğrulama kaybı(a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace	98
Şekil 5.19 Farklı veri tabanlarında Indepthnet19'e ait performans karşılaştırması, (a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace.....	98
Şekil 5.20 Indepthnet ROC eğrisi, (a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace	99
Şekil 5.21 Indepthnet Karşılaştırması, (a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace	99

Şekil 5.22 Deney 1’de performans değerlendirme için en yüksek değerli sonsal dağılım.....	103
Şekil 5.23 Deney 1’deki her sınıf için doğrulama sonuçları.....	103
Şekil 5.24 Deney 2’de performans değerlendirme için en yüksek değerli sonsal dağılım.....	104
Şekil 5.25 Deney 2’deki her sınıf için doğrulama sonuçları.....	105



TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1 Derin öğrenmenin özellikleri	25
Tablo 2.2 Her katman için derin yüz parametreleri	29
Tablo 4.1 Face94 veri tabanı özellikleri.....	50
Tablo 4.2 Bazı Face95 veri tabanı özellikleri	51
Tablo 4.3 Face96 yüz veri tabanı özellikleri	51
Tablo 4.4 Grimace yüz veri tabanının özellikleri.....	52
Tablo 4.5 Yüz tanıma veri tabanlarının özeti	55
Tablo 4.6 Karekök denklemi için sözde kod.....	58
Tablo 4.7 İkili değerin ondalık sayıya çevrimi	61
Tablo 4.8 Yüz tanıma için önerilen evrimsel sinir ağı modeli	73
Tablo 4.9 Indepthnet mimarisi	75
Tablo 5.1 Yale yüz veri tabanı üzerinde modern yöntemlerin tanıma oranları	93
Tablo 5.2 Face94 veritabanı üzerinde modern yöntemlerin tanıma oranları	94
Tablo 5.3 Genişletilmiş Yale B yüz veri tabanı üzerinde modern yöntemlerin tanıma oranları.....	95
Tablo 5.4 Bu çalışmada geliştirilen yöntemin diğer son yöntemlerle karşılaştırması.....	100
Tablo 5.5 Deney 1’deki her sınıf için sonsal sınıflandırma sonuçları.....	102
Tablo 5.6 Deney 2’deki her sınıf için sonsal sınıflandırma sonuçları.....	104

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

DSA	: Derin Sinir Ağları
DÖ	: Derin Öğrenme
DVM	: Destek Vektör Makinesi
ESA	: Evrişimsel Sinir Ağları
HDÇK	: Hata Düzeltme Çıktı kodları
EFA	: Evrişimsel Füzyon Ağları
YİÖ	: Yerel İkili Örüntü
YÜÖ	: Yerel Üçlü Örüntüler
YGH	: Yönlendirilmiş Gradyanların Histogramı'nı
TBA	: Temel Bileşenler Analizi
LDA	: Lineer Diskriminant Analizini
YSA	: Yapay Sinir Ağları
TSA	: Tekrarlayan Sinir Ağı
ÇKA	: Çok Katmanlı Algılayıcılar
MD	: Çoklu Tanımlayıcılar
OFYİÖ	: Ortogonal Farklılık-Yerel İkili Örüntü
HMM	: Hidden Markov Modeli
YN	: Yığın Normalleştirme
HE	: Histogram Eşitlemedir
BK	: Boyutsal Küçülme
AİK	: Alıcı İşletim Karakteristiği
EAA	: Eğrisi Altındaki Alan
AiA	: Ağ içinde Ağa
DDB	: Doğrultulmuş Doğrusal Birimin
GPO	: Gerçek Pozitif Orana
YPO	: Yanlış Pozitif Oranın
TB	: tamamen bağlı
ÇKA	: çok katmanlı algılayıcılar
GP	: Gerçek Pozitif
YP	: Yanlış Pozitif
GN	: Gerçek Negatif
YN	: Yanlış Negatif

1. GİRİŞ

1.1 Bağlam

Yüz tanıma, hem doğruluk hem de düşük seviyede müdahalecilik sağlayan az sayıdaki biyometrik teknolojiye biridir ve 1970'lerden beri güvenlik, görüntü işleme ve bilgisayarlı görü gibi alanlarda araştırmacıların dikkatini çekmiştir (Modi ve Patel, 2022; Waghunde vd., 2021). Yüz Tanıma bir görüntüdeki belirli bir insanı örüntüleri inceleyerek tanımlamak ve doğrulamak için kullanılan en yaygın biyometrik yazılım uygulamaları arasında yer alan etkili bir tekniktir. Yüz tanıma, örüntü tanıma ve bilgisayarlı görü araştırmalarında çok çeşitli pratik uygulamaları bulunan önemli bir konudur (Hadiprakoso ve Buana, 2021; Khan vd., 2018). Bilgisayarlı görü alanı, insanoğlunun kaydettiği birçok teknolojik ilerlemenin öyküsü arasında kendine özgü bir konuma sahiptir (Venkatesan ve Li, 2017). Bilgisayar bilimi ve bilgi teknolojileri, IBM'in 1981'de ilk bilgisayarı piyasaya sürmesini takiben 2000'lerin başındaki dot-com dönemi, son on yılda online alışverişin yaygınlaşması ve şimdi de Nesnelerin İnterneti ile hızlı bir şekilde toplumla bütünleşmektedir. Dijital ve fiziksel dünyanın giderek daha fazla iç içe geçmesiyle bireylerin güvenli ve başarılı bir şekilde nasıl tanınacağı ve aynı zamanda bilgi sistemlerinin nasıl iyileştirileceği sorusu önemli bir çalışma konusu haline gelmektedir. Bu bağlamda tüm dünyada yetkililerce yeni tanımlama teknolojilerinin geliştirilmesi teşvik edilmekte ve bu konuda bazı önemli taleplerde bulunmaktadır. Geleneksel kimlik tanıma yöntemleri, çoğunlukla kişinin hafızasına (parolalar, kullanıcı adları vb.) veya yabancı öğelere bağlıdır. Bununla birlikte, hem yabancı öğeler hem de kişinin belleğinden kaynaklanabilecek büyük güvenlik tehditleri bulunmaktadır. Kimliklerini doğrulayan kimlik materyalleri çalınırsa veya kaybedilirse, kimlik verilerinin tekrar elde edilmesi imkansız değildir. Ancak kimlik bilgileri başkaları tarafından da kolaylıkla elde edilebilmektedir. Sonuç olarak, kimliğin bir başkası tarafından ele geçirilmesi büyük sonuçlar doğurabilmektedir.

Standart kimlik tanıma teknolojilerinin aksine, biyometrik sistemlerde tanıma için vücudun parmak izi, iris, yüz gibi doğal özelliklerinin kullanılmaktadır. Biyolojik

özellikler standart kimlik tanıma sistemlerine göre önemli derecede avantajlıdır. Ayrıca, tekrarlanabilirlik insanların genetik olarak aktarılan doğal bir nitelik olduğundan biyolojik özellikler üzerinde değişiklik yapmak zordur.

İnsan vücudunun bir parçası olan biyolojik özellikler, kolayca erişilebilir, kullanılabilir ve asla ortadan kaldırılamaz. Bu özelliklerin kullanımı kolaydır. Birçok biyolojik özellik, kişilerin test cihazı ile işbirliği yapmasını gerektirmeyecektir. Biyometri, daha önce sıralanan özellikleri nedeniyle büyük kuruluşların ve araştırma üniversitelerinin ilgisini çekmiş ve birçok disiplinde geleneksel tanıma yöntemlerini etkin bir şekilde değiştirmiştir. Biyometri teknolojisi, otomatik kontrol uygulamak için bilgisayarları ve ağlarını kullanmaktadır ve bilgisayar ve yapay zekanın hızlı gelişimi sayesinde günlük yaşamla hızla bütünleşmektedir. Tanıma, yüz algılama ve hizalama işleminden sonra farklı öznelik çıkarma yöntemleri kullanılarak yapılmaktadır. (Verma vd., 2022). Bir fotoğraf veya videodan bir kişiyi tanıma ve doğrulama işlemi, yüz tanıma olarak bilinmektedir. Önceki çalışmalarda yüz tanıma ve doğrulama teknikleri alanında önemli ilerlemeler kaydedilmiştir. Yüz tanıma alanında daha doğru sonuçlara yol açan modeller geliştirebilmek için yoğun araştırmalar yapılmaktadır (Kamra, 2021). Yüz tanımanın özellikle güvenlik ve yoklama sistemlerinde tanımlama ve kimlik doğrulamada büyük önemi vardır. Herhangi bir tanıma tekniğindeki temel yöntem, tanınacak nesnenin fiziksel özelliklerini yorumlamaktır. Biyometrik tanıma tekniği, bilimin ilerlemesi ve yeniliklerin artması için yaygın olarak kullanılmaktadır. Parmak izi ve iris tanıma gibi diğer tekniklerle karşılaştırıldığında, yüz tanıma daha iyi bir tekniktir.

Yüz tanımadaki diğer sorunların çoğu genellikle poz, ölçek, yönelim, aydınlatma (Pandey ve Gupta, 2022) ve yüz ifadesi ile ilgilidir. Zaman içinde bu sorunları çözmek için çok sayıda yöntem önerilmiştir. Ayrıca, farklı ışıklandırma koşulları, pozlar, oklüzyon ve kameradan uzaklık nedeniyle kontrollü ve kontrolsüz ortamlar karmaşık hale gelmiştir. Farklı açılar ve ışıklandırmalar yüz özelliklerini etkileyerek fiziksel özellikleri olduğundan farklı gösterir (Gupta vd., 2021). Gerçek ortamlarda yüz tanıma, pozlar, ışıklandırma ve oklüzyonlar gibi çeşitli faktörler nedeniyle zor olmuştur. Son yıllarda farklı ışıklandırma koşullarında yüz tanıma için kullanılan çeşitli yöntemler vardır. Tanıma teknikleri kontrollü ve kontrolsüz ortamlarda

ışıklandırma ve poz varyasyonları gibi zor koşullarda iyi performans göstermiştir. Yüz görüntülerinin ışıklandırılmasındaki farklılıklar, görüntü alınırken ışık kaynağının yüzün yönüne farklı açılarda konumlandırılmış olduğunda meydana gelmektedir. (Liang vd., 2021). Yüz tanımadaki en temel zorluklardan biri olan aydınlatma farklılıkları görüntü işleme ve örüntü tanımlama için önemlidir. Bazı durumlarda, tüm yüz görüntüleri eğitimden önce mevcut olmayabilir veya yüz görüntüleri farklı coğrafi bölgelerden edinilecek olabilir (Madhavan ve Kumar, 2021; Peña vd., 2021). Günümüzün yüz tanıma teknolojisinin yüksek doğruluk oranına rağmen, teknikler hala birçok değişikene karşı hassaslık gösterebilmektedir. Örneğin, yüz ifadesi yanlılığı, yüz tanıma sistemlerinin doğruluğunu etkilemektedir (Abdullah ve Stephan, 2021). Yüz ifadesi, bilgi iletmek için ifadeleri kullanan sözsüz bir bilgi alışverişidir. Bununla birlikte, yüz ifadesi farklılıkları yüz tanıma algoritmaları için bir zorluk teşkil etmektedir (Erakın vd., 2021).

Yüz tanıma için temel konulardan biri de oklüzyon nedeniyle yüz özelliklerinde gözlenen farklılıklardır. (Biswas ve Blanco-Medina, 2021). Oklüzyon, yüz tanımının en büyük engellerinden biridir (Athreya vd., 2021). Sınırsız görünen durumlar nedeniyle, oklüzyona uğramış yüzleri tanıma, alanın uzmanları için önemli bir görev olmuştur (Abiero vd., 2022). Yüz tanıma performansı, atkı, maske ve gözlük gibi kısmi yüz oklüzyonlarından olumsuz etkilenmektedir (Jiang vd., 2022). Evrensel yüz tanıma algoritmalarının performans düşüşündeki en önemli faktörlerden biri oklüzyondur.

Tanımada büyük ilerleme kaydedilmiş olmasına rağmen, yüz tanıma ve tanıma görevlerinde hala önemli sorunlar bulunmaktadır (Reddy ve Kumar, 2021). Poz, yüz ifadeleri ve ışıklandırmadaki farklılıklar gibi engeller yüz tanıma ve doğrulamayı zorlaştırmaktadır (Yu vd., 2021). Doğada yüz tanıma, aydınlatma, gölgeleme ve yüz kası özellikleri dahil olmak üzere çeşitli parametrelerden etkilenir. Ayrıca, aynı kişiye ait fotoğraflar, iç veya dış ortamda çekilmesine bağlı olarak önemli ölçüde farklılık göstermektedir. Bu unsurlar değiştirildiğinde yüz tanıma etkinliği önemli ölçüde azalmakta ve yüz tanımının etkililiği zayıflamaktadır. Kafa duruşu, ölçekleme, aydınlatma varyasyonları, çevre bölümlendirme ve oklüzyon yüz tanımada sınırlılıklara yol açabilmektedir. Yüz tanıma, birçok bilgisayarlı görü uygulamasında kullanılan kimlik doğrulama tekniklerinden biridir (Pei vd., 2019; Tran vd., 2021).

Aydınlatma ve konum dahil olmak üzere farklı çevresel koşullar altında yüz tanıma, bilgisayarlı görü için zorlayıcı bir konu olmayı sürdürmektedir (Hassanpour ve Ghasemi, 2021; Somogyi, 2021). Yüz tanıma, kolluk kuvvetleri, izleme ve güvenlik sistemleri, akıllı ofisler ve evler dahil olmak üzere çeşitli pratik sistemlerde kullanılabilir (Marenkov vd., 2021).

Yüz tanıma teknolojisi, işletmelerin bilgi güvenliğini geliştirmesini ve sonuç olarak, yasal kullanıcıları kullanan bir erişim kontrol sistemi aracılığıyla güvenli bir alana yetkisiz girişten kaynaklanan varlıklarına yönelik finansal saldırı riskini en aza indirmesini sağlar (He ve Jiang, 2022). Dijital bir görüntüdeki veya video karesindeki bir insan yüzünü bir veri tabanındaki yüzlerden biriyle eşleştirmeyi amaçlayan gerçek zamanlı yüz tanıma, çeşitli alanlarda giderek daha fazla uygulama alanı bulmaktadır.

Mevcut yüz tanıma teknolojileri tanımlamadan eğlenceye çeşitli nedenlerle işlevlerini yerine getirmek için farklı sınıflandırma teknikleri kullanmaktadır. (Giovani vd., 2021). Yüz tanıma, insanların yüzlerinin fotoğraflarına veya (gerçek zamanlı tanıma ise) bir kameraya dayalı olan ve yoklama sürecini kaydetmenin daha geleneksel bir yöntemi olduğundan popüler bir araştırma konusudur. Yoklama, eğitimde günlük değerlendirmenin önemli bir parçasıdır. Aynı nedenle, öğretim yapan kuruluşlar öğrencilerinin katılımını izlemek için hızlı ve güvenilir bir mekanizmaya ihtiyaç duymaktadır. Bu alandaki teknolojiler bir bireyin "gerçek" kimliğini doğrulamayı kolaylaştırmıştır. Biyometri, bu yöntemde benimsenen sistem için kullanılan terimdir. Biyometrik sistem, bir kişiyi, tahrif edilmesi imkansız olan biyolojik özelliklerine göre tanımaktadır. Biyometrik bir teknoloji olarak yüz tanıma, yüksek doğruluk ve düşük müdahalecilik avantajlarına sahiptir. Bu tez, uzaktan eğitim kaydında yüz tanımaya odaklanmaktadır. Yüz tanımanın uzaktan öğrenmeye yardımcı olabilecek ve tüm eğitim sürecini doğrudan destekleyebilecek değerli bir biyometrik teknoloji olduğuna inanılmaktadır.

Bu araştırma, yeni ESA'nın yüz tanıma ve yoklama için uygulanmasına katkıda bulunmaktadır. Bu çalışmada önerilen modelin tüm yapısı test edilecek, öğretilecek ve genel tanıma sistemini kontrol etmek için diğer teknikleri uygulanacaktır.

1.2 Yüz Tanıma ve Yoklama Problemleri

Önemli teknolojik gelişmelerden biri olan ve bir görüntüyü yakalamak, bir yüzü tanımak ve bir fotoğrafı bir veri tabanında saklamaktan ibaret olan yüz tanıma, birkaç üst düzey teknoloji kullanmasına rağmen yoğun uygulama alanı bulmuştur. Bununla birlikte, yüz tanıma koşullara ve çevreye uyum sağlayabilirse faydalı olmaktadır. Günümüzün yüz tanıma uygulamalarında bu özellik eksiktir. Tüm biyometri, yüz algılama, yüz ön işleme ve yüz tanıma işlemlerini içermektedir. Yüz algılama tekniği ile yüz bölgesi alınarak ve yüz ortamdan ayırt edilerek farklı ayırt edici öz niteliklerin çıkarımı için kullanılmaktadır.

Diğer yöntemlere kıyasla, derin öğrenmeye dayalı yüz tanıma sistemlerinin süreyi kısaltıp doğruluk oranını artırabilir. Ayrılmış yüzlerin tanınması, insan yüzlerini tanımlamak için normalize edilmiş yüz görüntülerinden öz niteliklerin çıkarılması ve tanımlanması için kullanılan bir yöntemdir.

Bu tez, yeni yüz tanıma tekniklerine dayalı bir yoklama sisteminin geliştirilmesini ele almaktadır. Özellikle, aşağıdaki araştırma problemleri araştırılmaktadır:

1. Farklı aydınlatmalar, pozlar, yüz ifadeleri ve yüzlerin kapanması gibi engeller yüz özelliklerini tanımlayıcı yöntemlerde tanıma sonuçlarını etkileyebileceğinden, farklı yüz görüntülerine izin veren bir yöntem ihtiyacı duyulmaktadır.
2. Aydınlatma, poz, yüz ifadesi ve oklüzyon çeşitliliği nedeniyle güvenli, doğru ve güvenilir yüz tanıma sağlamak için aşılması gereken engeller bulunduğundan bu alanda daha fazla çalışmaya ihtiyaç duyulmaktadır. Bu çalışmada bu engellerin bazılarını ortadan kaldıran yeni bir yüz tanıma modeli geliştirilmektedir.
3. Birçok durumda derin yüz tanıma tekniklerinin insanlardan daha iyi performans gösterdiği görülmektedir. Bunun yanında, insan operatörleri yüz tanıma desteklemek için derin öğrenme modellerini kullanmayı amaçlayan çalışmalar da bulunmaktadır. Bu sorunun daha iyi anlaşılması, uygulanabilir bir pratik sistem geliştirmeye yardımcı olacaktır.

4. Uzaktan öğrenmede temel doğrulamayı kullanmanın getirdiği birçok sorun etkililiği azaltmaktadır. Henüz çözüm öneren çok sayıda araştırma bulunmadığından, bu çalışmada uzaktan eğitimde yüz tanımanın nasıl uygulanacağı ayrıntılı olarak açıklanacaktır. Eğitim verilerinin eksikliği ve etkili politikaların eksikliği de uzaktan eğitimde yüz tanımayı daha verimli hale getirmenin önünde engel teşkil etmektedir.

1.3 Çalışmanın Amacı

Bu tezde, yüz tanıma alanında yüz öznitelik tanımlayıcı yöntemlerin önemli avantajları araştırılmaktadır. Bu yöntemler tüm yüz tanıma performansını iyileştirebileceğinden oldukça önemlidir. Ayrıca güvenli, doğru ve güvenilir yüz tanımanın önündeki engelleri aşan yüz tanıma modellerinin nasıl geliştirileceği sorusunun cevabı da bir başka büyük zorluktur. Yüz tanıma alanında sorulması gereken soru şudur: Neden derin sinir ağları çelişen örnekleri insanlardan daha kolay anlayabilmektedir? Uzaktan eğitimde yüz tanımanın nasıl verimli bir şekilde uygulanacağını açıklayan çözümler öneren az sayıda araştırma olduğundan, laboratuvar ortamındaki ve gerçek hayattaki uygulamalar arasındaki farklılıklar daha zorlaştırıcı olabilir.

Bu tez, yüz tanıma ile uzaktan öğrenme ortamlarını iyileştiren yeni yöntemler sunmaktadır. Yukarıdaki araştırma problemleriyle ilgili zorlukların üstesinden gelmek için aşağıdaki hedefler belirlenmiştir:

1. Yüz tanıma için yeni bir öznitelik çıkarım yönteminin geliştirilmesi: Çoklu tanımlayıcı adı verilen yeni model, iyi bilinen yerel ikili örüntü yöntemine dayanmaktadır. Merkezi pikselin birçok farklı komşusunu içeren modelin belirleyici özelliği, bu tanımlayıcının sadece bir nokta yerine farklı komşuluk boyutlarının kullanılmasına izin vermesidir. Bu yapı, makul bir etkililik düzeyi ve farklı bir öznitelik dağılımı elde etme imkanı sağlamaktadır.

2. Yüz tanıma ve kaydı geliştirmek için yeni fakat oldukça etkili bir evrimsel sinir ağının geliştirilmesi: Önerilen modelimiz, sıralı ve artık kimlik bloklarının bir kombinasyonuna dayanmaktadır. Böylece, diğer modellerden daha derin bloklar kullanarak etkililiği artırmak amaçlanmaktadır.

3. Uzaktan eğitimde yüz tanıma ve yoklama için bir mimari geliştirilmesi: Bu çalışmanın avantajlarından biri, önerilen model ve Destek Vektör Makinesi kullanılarak çıkarılan ve eğitilen özniteliklerdir. Bu çalışmada yeni bir ESA modeline ve bir Destek vektör makine modeline dayalı yeni bir hibrit sınıflandırma mimarisi önerilmektedir.

4. Önerilen yöntemlerin diğer alanlara katkıda bulunabileceğinin kanıtlanması.

Yüz özniteliği çıkarımı yöntemindeki gelişmeler, yüz tanıma ve diğer alanlara katkı sağlamıştır. Merkezi pikselin birçok farklı komşusuna odaklanmaya izin veren öznitelik çıkarma yöntemi önerilmektedir. Bu yapı, makul bir etkililik düzeyi ve farklı bir öznitelik dağılımı elde etme imkanı sağlar. Yüz öznitelik çıkarma modeli deneysel araştırmalarla değerlendirilir. Bu çalışmada sıralı ve artık kimlik bloklarının bir kombinasyonuna dayanan derin evrimsel sinir ağları önerilmektedir. Yüz tanıma için modellerini doğrulamak ve seçmek için deneysel çalışmalar kullanılır. Uzaktan eğitimde yüz tanımanın nasıl iyileştirileceğine dair az sayıda araştırma yapılmıştır. Yüz tanımanın gerçek sistemlere etkin bir şekilde dahil edilmesinin önünde birçok engel bulunabilir. Bu çalışmada uzaktan eğitimde yüz tanımanın nasıl uygulanacağına dair içgörüler ortaya çıkarmak ve algoritmalar geliştirmek için deneysel bir araştırma deseni kullanılmıştır.


1.4 Çalışmanın Önemi

Bu araştırmanın temel amacı, yüz tanıma ve yoklama için yeni yüz öznitelik çıkarma teknikleri geliştirmektir. Bu tezin alana önemli katkıları bulunmaktadır. İlk olarak, yüz özniteliklerini göstermek için açıkça yüzün sınırları, burun ve gözler üzerinde yoğunlaşan yeni bir yöntem kullanılmaktadır. İkincisi, yüzün tüm özniteliklerini temsil etme yeteneğini ile yüz ayrıntılarını tanımlamaya katkı sağlamasıdır. Üçüncü olarak, derin öğrenmeyi kullanarak pratik uygulamalar geliştirmeye yardımcı olabilecek güvenli, doğru ve güvenilir yüz tanıma geliştirilmesidir. Uzaktan eğitimde yüz tanıma önemli bir uygulamadır ve yüz tanıma yöntemlerini kullanarak öğrenenin doğrulanmasını sağlayarak eğitim sürecine doğrudan yardımcı olmaktadır. Yeni yöntem ve tekniklerin yüz tanıma alanında çok verimli olduğu kanıtlanmıştır ve

COVID-19, retina damarları, doku sınıflandırması vb. başka işlevlerin yürütülmesine de katkıda bulunabilir.

1.5 Tezin Yapısı

Bu tez, yeni yüz tanıma tekniklerine dayalı bir yoklama sisteminin oluşturulmasını amaçlamaktadır. Başlangıç olarak, bu tezde, poz değişimi, aydınlatma değişimi, ifade değişimi ve oklüzyon gibi yüz tanımadaki önemli engellerin etkisinin bir incelemesi sunulmakta; ve ikincisi, uzaktan eğitim kaydı için verimli olan bir dizi benzersiz yüz tanıma algoritması verilmektedir. Tez bölümlerinin yapısı Şekil 1.1'de gösterilmiştir. Her bölümün ayrıntılı katkısı aşağıdaki gibidir:



Şekil 1.1 Tezin yapısı

Yapılan deneysel bir yüz tanıma çalışması anlatılmaktadır. Yüz tanıma yöntemleri mühendislik ve derin öğrenme yöntemleri olarak iki kategoriye ayrılmaktadır. Uzaktan öğrenmede yeni bir yüz tanıma yöntemi açıklanmakta, uygulama ve yöntemin aşamaları hakkında bilgi verilmektedir. Yüz tanıma teknolojisi uygulamalarının örnekleri ve umut vadeden geleceği gözden geçirilmektedir. Birçok büyük kuruluş ve araştırmacı tarafından bu alana büyük miktarda çaba harcanmakta ve çalışmalar yapılmaktadır. Olarak yüz bölgesini iyileştiren yeni bir filtre tasarlanmıştır. Bu ön işleme filtresinin tasarlanmasının ana amacı, yüz görüntüsünü siyah beyazdan yeni bir görünüme dönüştürmektir. Yeni bir görünümle örüntüde gerçekleşen iyileştirmenin sonuçları nasıl iyileştirebileceği gösterilmektedir. Karekök denklemi (KKD) denklem operatörünün arkasındaki temel ilke şu şekildedir: İlk adım, yüz resmini siyah beyaza dönüştürmektir. İkinci adım, bir (m-n) resimde 3-3 penceresinin merkez noktasını piksel noktası (xT, yT) olarak kullanmaktır. Üçüncü adım, komşu sekiz piksel

değerleri a_0 - a_7 olacak şekilde, merkez noktası (g_T) etrafındaki piksel değerinin (x_T , y_T) karekökünü almaktır. Yüz görüntüsü tanımlayıcıları etkin öznitelik gösterimi için kullanılan temel teknoloji olduğundan, bu çalışmada yüz tanıma uygulamaları için yeni yüz görüntüsü tanımlayıcıları geliştirilmiştir. Yüz görüntüsü tanımlayıcısı "Çoklu tanımlayıcılar" (ÇT) olarak adlandırılır. Merkez pikselin birçok farklı komşusu ele alınmaktadır. Bu tanımlayıcının ayırt edici özelliği, sadece bir nokta yerine çeşitli komşuluk boyutlarının kullanımına izin vermesidir. Bu yapı, yeterli etkinliği sağlarken aynı zamanda farklı öznitelik dağılımlarına izin vererek, önceki el yapımı yüz resmi tanımlayıcılarından daha ayrıntılı ve ayırt edici hale getirmektedir. Yüz görüntüsü tanımlayıcıları üzerine yapılan araştırmalara dayanarak, bu çalışmada yüz tanımadaki en zor durumlar araştırılmaktadır. Önerilen algoritma orijinalinden daha iyi performans göstermektedir. ÇT daha çok yüz görüntülerinin ayırt edici dokusunu kullanan yeni bir yüz görüntüsü tanımlayıcısıdır. Hızlı ve doğrudur ve bilgi işlem maliyeti, poz ve ifade değişikliklerine son derece dirençli olmakla birlikte, yerel ikili örüntülerle benzerdir. ÇT, çeşitli seviyelerden bir yüz resminin özniteliklerini tamamen ve etkili bir şekilde son derece açıklayıcı ve ayırt edici şekilde tanımlayabilmektedir. Derin öğrenme modeline dayalı olarak, yüz görüntülerini otomatik olarak öğrenen "Yüz Tanıma ve Yoklama için Güçlü Bir Derinlemesine Ağ Öğrenme Yapısı" adlı bir model tasarlanmıştır. Çekirdek ağ, orijinal yüz görüntüsünden bilgi çıkarmak için genişletilmiş blok için hem ortalama hem de maksimum ortaklama ile bloğun son çıktısını tamamlamak için ortalama ortaklamanın erken katmandan önce geldiği bir öğrenme mimarisine sahiptir. Yüz tanıma ve yoklama için yeni bir ESA modeli önerilmiştir. Dijital olarak mevcut olan eğitim verilerinin elde edilmesinin zorluğu uzaktan eğitimde yüz tanımanın kullanımını engelleyebilmektedir. Bu çalışmada veri dönüştürme ve çoğaltma kullanılarak bu engellere nasıl yaklaşılabileceği ve bunların nasıl aşılabileceği gösterilmektedir. Önerilen ESA'da yüz öznitelikleri küçük veri tabanları için ideal olan ve yüz tanıma hatalarını azaltan Softmax ve Destek Vektör Makinesi kullanılarak ayıklanmış ve eğitilmiştir. Tüm veri tabanları için gerçek zamanlı sistemlerde yüz tanımayı iyileştirerek doğrulama safhasına yardımcı olan Destek Vektör Makinesini kullanmanın büyük faydası bulunmaktadır. Başarılı bir şekilde doğrulanan örneklerin sayısına dayalı bir nihai karar değeri olarak çoklu tanımlayıcı kullanmak, yanlış sınıflandırmayı ortadan

kaldırarak ve performansı iyileştirecektir. sonuçlar tartışılmakta ve gelecek araştırmalar için önerilerde bulunmaktadır.



2. LİTERATÜR TARAMASI

Bu bölümün amacı, küresel, yerel ve yapay zeka yaklaşımlarını kullanarak yüz öznitelik çıkarma yöntemlerinin güncel bir değerlendirmesini sağlamak ve en son teknolojiye dair bir inceleme yapmaktır. Bu çalışma, yüz tanıma ve yoklama için yerel öznitelik tabanlı ve yapay zeka yaklaşımlarına odaklandığından bölümün önemli bir kısmı bu yaklaşımlara ayrılmıştır

Yüz tanımanın da dahil olduğu biyometrik teknoloji kavramı, son zamanlarda ortaya çıkan sistemlerde önemli yer tutmaktadır. Öte yandan, dünyanın dört bir yanından birçok mühendis ve bilim adamı, günlük hayatta bu tür sistemler için giderek daha verimli algoritmalar ve yaklaşımlar geliştirmeye çalışmaktadır. Alternatif kimlik doğrulama çözümlerinin çoğunda tüm kişisel bilgilerin arşivlenmesi gerekmektedir. Neyse ki, bilgi teknolojisi ve güvenlik algoritmaları geliştirildikçe tanıma görevi için biyometrik özelliklerin bir kısmını entegre eden sistemler ortaya çıkmaktadır. Bu biyometrik özellikler, fiziksel veya davranışsal özelliklere sahip oldukları için kişinin kimliğini belirlemeye yardımcı olmaktadır. Kişiler için de algılayıcının yetki alanının doğru olması durumunda kullanıcı adı ve şifre veya özel kodları ezberleme ihtiyacını ortadan kaldırarak faydalı olmaktadır.

İnsanları biyolojik özelliklerine göre sınıflandıran yöntemlerin kullanımının basit olması, bu yöntemlerin yaygın olarak kullanılmasını sağlamaktadır. Tanıma süreci birkaç aşamadan oluşur. İşlevi ve çeşitli alanlarda (izleme, güvenlik sistemleri, gümrük kontrolleri vb.) kullanımı göz önüne alındığında, son yıllarda en yaygın kullanılan biyometrik tanımlama teknolojilerinden biri haline gelmiştir.

Çeşitli arama türleri aracılığıyla geliştirilen biyometrik teknolojiler, iyi bir tanımlama performansı sağlar. Bu nedenle, gerçek zamanlı kısıtlamaları karşılamak için yüz tanımaya yönelik yeni biyometrik teknolojiler halihazırda geliştirilmektedir. Geleneksel bilgisayar yaklaşımları, özellikle öznitelik çıkarma ile doğrudan ilgili olan karmaşık uygulamalar için, üretilen veri hacminin yanı sıra makine öğrenme tekniklerinin ilerleyişi nedeniyle, veri analizi için yetersiz hale gelmiştir.

Yüz tanıma, parmak izi ve iris tanıma dahil olmak üzere diğer biyometrik algoritmalara göre çeşitli üstünlüklere sahiptir. Yüz tanımanın doğallığı ve müdahaleci olmamasının yanı sıra uzaktan ve görünmez bir şekilde elde edilebilmesi de yüz tanımanın başlıca avantajlarını oluşturmaktadır. Yoklama, geçerlilik, makine kısıtlamaları ve genel algı gibi bir dizi değerlendirme kriterine dayalı olarak yüz öznetelikleri, en yüksek kabul oranını Makinece Okunabilir Seyahat Belgeleri (MOSB) mimarisinde elde etmiştir. Yüz tanıma, görüntü elde etme teknolojisindeki (güvenlik kameraları, cep telefonu kameraları) hızlı gelişmeler, İnternette büyük miktarda yüz görüntüsünün bulunması ve artan güvenlik gereksinimlerinin bir sonucu olarak en önemli biyometrik yöntemlerden biri olarak ortaya çıkmıştır.

Kullanılan yöntemlerin altını çizmenin yanı sıra, yüz tanımayı doğru bir şekilde gerçekleştirmek için ele alınması ve üstesinden gelinmesi gereken zorlukların kısa bir açıklamasını sunmak büyük önem taşımaktadır. Uzaktan eğitim için yoklama yüz tanıma ile doğrudan ilişkili olup bu çalışmanın anlaşılabilmesi için bilinmesi gereken önemli bir terimdir. Yüz tanıma ile gerçek hayat uygulamaları arasında büyük fark vardır. Yüz tanıma sonuçlarının tümü iyi bir doğruluk oranı elde etmiş ve bunu sunmuşsa da, bu oranların laboratuvar ortamında elde edilmek gibi bir sınırlılığı bulunmaktadır. Bu nedenle, bu çalışmada temel olarak uzaktan eğitim kaydıyla ilgili yüz tanıma zorluklarına ve araştırmalar ile endüstriyel uygulamalar arasındaki ayrıma odaklanılmaktadır. Bu bölümde konuya odaklanan nispeten az araştırma olduğu için, uzaktan öğrenmede yüz tanımanın nasıl kullanılacağı açıklanmaktadır. Uzaktan eğitimde yüz tanımayı daha verimli hale getirmek konusunda eğitim verilerinin ve iyi yönergelerin eksikliği sınırlayıcı olmaktadır. Güvenli, doğru ve güvenilir bir yüz tanıma sağlamak için çözülmesi gereken sorunlar bulunmakla birlikte, bunlar ancak iyi tasarlanmış yeni bir yüz tanıma modeli geliştirilerek ortadan kaldırılabilecektir. Derin yüz tanıma yöntemlerinin artık insan performansını aştığı düşünülmektedir. İnsan operatörlere yüz tanımada yardımcı olmak için derin öğrenme modellerini uygulamak için yapılan umut vadeden çalışmalar da bulunmaktadır. Bu gelişmelerin yanında, derin sinir ağlarının bazı görüntüleri nasıl insanlardan daha kolay tanıyabildiği de dahil olmak üzere bir dizi cevapsız soru bulunmaktadır.

Geçerli bir yüz tanıma için üç temel aşama bulunmaktadır: yüz algılama, yüz çıkarımı ve yüz tanıma. Yüz Algılama Adımında aygıt tarafından ele alınan bir insan yüzünün görüntüsünü algılanır ve düzeltilir. İlk aşamada, herhangi bir yüz resmi için öznitelik vektörlerini elde etmek için öznitelik çıkarma aşaması kullanılır. Yüz konumunun değişmesi tanıma sonuçlarını etkileyebileceğinden, yüz özniteliklerini tanımlayıcı yaklaşımlar tanıma zorlanacağından çeşitli yüz görüntülerini inceleyen bir yöntemin kullanılması gerekebilir. Öznitelik Çıkarma: Bu adımın birincil amacı, algılama işlemi sırasında tanımlanan yüz fotoğraflarının özniteliklerini çıkarmaktır. Bu adım, yüz resminin yapısını öznitelikler açısından ortaya koymak için yüzü, ağız, gözler ve burun dahil olmak üzere vektörler olarak düzenler. Her yüz şekil, yapı ve boyut açısından benzersizdir ve bu da yüzün özniteliklerini ortaya çıkarılmasına olanak tanır. Bunu takiben, yüz tanıma adımı, yüz görüntüsünden özniteliklerin çıkarılmasını ve yüz görüntüsünün konumunu doğrulamak için tüm yüz fotoğrafları dizisiyle eşleştirilmesini gerektirir.

Bu tez, yüz tanıma ve uzaktan eğitim kaydını geliştiren yeni yöntemler önermekte, araştırma problemlerini ile ilgili zorlukları ele almakta ve yeni bir yüz tanıma özniteliği çıkarım yaklaşımı ortaya koymaktadır. Yüz tanıma ve kaydı geliştirmek için özgün ve yüksek düzeyde verimli bir evrimsel sinir ağı geliştirilmiştir. Uzaktan eğitim durumunda, yüz tanıma ve yoklama için bir altyapı sağlanmış ve ortaya konulan yaklaşımların diğer disiplinlere nasıl katkıda bulunabileceği gösterilmiştir.

Yüz tanıma adımı çıkarım aşamasında görüntüden çıkarılan öznitelikler, bir veritabanı sisteminde saklanan bilinen kişilerle karşılaştırılır. Yüz tanıma temel olarak iki yöntem vardır; biri tanımlama, diğeri doğrulama olarak bilinir. Tanımlama aşamasında, en olası eşleşmeyi bulmak için test yüzü bir dizi yüzle karşılaştırılır, ancak doğrulama aşamasında, bir test yüzü, kabul veya ret edileceğini belirlemek için veri tabanındaki bilinen bir yüzle karşılaştırılır.

Parmak izi, göz ve yüz tanıma gibi biyometrik yöntemlerin kullanılması durumunda uzaktan öğrenmenin kaydı küresel bir sorun haline gelmektedir. Yüz özniteliği üzerinde yapılan çalışmalar uzaktan eğitim için önem taşımaktadır. Bu alanda yüz öznitelikleri neden bu kadar önemlidir? Bu sorunun cevabı bu çalışmanın amacına

açıklık getirebilir. Yüz öznitelikleri uzun süre değişmeden kalmaktadır. Bu bize uzaktan eğitimde yüz özniteliklerini kimlik doğrulama araçları olarak kullanma avantajını sağlar. Yüz tanıma, kullanım kolaylığı, kullanıcı dostu olması ve yüz tanımayı gerçekleştirmek için herhangi bir işlem yapılmasına gerek olmaması gibi birçok avantaja sahiptir. Tanıma, tanımlama, sınıflandırma ve doğrulama için kullanılan bir terimdir, ancak yüz tanıma, yüzün kimliğini saptama anlamına gelir. Bu iki terim birbirinden tamamen farklı olduğu için dikkatli bir şekilde ayırt edilmeleri gerekmektedir.

Yüz tanıma alanında, araştırma ve uygulama arasında farklılık vardır. Neredeyse tüm yüz tanıma algoritmaları gerçek hayat uygulamalarında gerçek performansın ne olduğu açıklanmadan veya belirli görevlerde karşılaşılan zorluklara yönelik olarak laboratuvar ortamında tasarlanmıştır. Araştırılan problemi açık bir şekilde ele alan ve gerçek hayattaki uygulamalar için doğru bilgi ve yönergeleri veren bir model geliştirilmesi gerekmektedir. Bu alanda ele alınması gereken zorluk ve gereksinimler de bu ihtiyaca işaret etmektedir. Farklı özelliklerle yüksek doğruluk elde etmek için yüz tanıma algoritmaları geliştirilmelidir.

Uzaktan eğitim, 2020'deki COVID-19 salgınının da etkisiyle birçok ülkede eğitimin verilme şeklini büyük ölçüde değiştirerek öğrenme kültüründe küresel bir sorun öneme sahip olmuştur (Li, 2021; Nazarova vd., 2021). Geleneksel eğitim uygulamaları, İnternet tabanlı, bilgisayarda yapılan çevrimiçi eğitime dönüşmüştür (Mu ve Guo, 2022). Bu dönüşümde en önemli faktör sosyal mesafe ve güvenlik zorunluluğudur (Abdullaev, 2020; Abduraximovich, 2021). Çevrimiçi eğitim, öğretmen ve öğrencilerin fiziksel olarak aynı yerde bulunmadıkları öğrenme sürecini ifade etmek için kullanılan terimlerden biridir. Çevrimiçi öğrenme ve uzaktan eğitim gibi aynı anlama gelen birçok farklı terim vardır. Çevrimiçi bir sınıfta, öğretmen ve öğrenci birbirleriyle etkileşime girebilmektedir. Öte yandan yakın gibi olsalar da ama değildirler. Öğretme ve öğrenme süreci, çevrimiçi dersi destekleyen video görüşmeleri yoluyla yapılır. Öğretmen ve öğrenci arasındaki iletişim, görüntülü sohbet veya video konferans yoluyla ideal öğrenme şekli olan yüz yüze durumuna gelebilir.

Uzaktan öğretim yapan eğitimcilerin karşılaştığı sorunlardan biri, çevrimiçi öğretimin öğretim ve değerlendirme gibi farklı aşamalarında öğrenenlerin doğrulanmasıdır. Öğrenenlerin doğrulanması, tanıma teknolojileri ile sağlanır. Birçok uzaktan eğitim sisteminde, katılımcının gerçek bir kişi olup olmadığını veya derse aktif olarak devam edip etmediğini bilmek mümkün değildir (Özdemir ve Uğur, 2021a). Bu tez, yoklama durumunda yüz tanıma konusuna odaklanmaktadır. Yüz tanımanın uzaktan öğrenmeye yardımcı olabilecek ve tüm eğitim sürecini doğrudan destekleyebilecek değerli bir biyometrik teknoloji olduğuna inanılmaktadır. Bu bölümün katkısı, yüz tanıma ve yoklama için yeni bir modeldir. Bu bölümde önerilen modelin tüm yapısı eğitilmiş ve test edilmiş, sistemin genel olarak tanınmasını ve kaydını kontrol etmek için çeşitli yöntemler uygulanmıştır.

Tanıma alanındaki önemli gelişmelere rağmen, yüz tanımanın önünde büyük engeller bulunabilmektedir. Bu sınırlılıklar baş pozisyonu, ölçekleme, ışıklandırma varyasyonları, çevrenin betimlenmesi ve oklüzyon olarak sayılabilir. Yüz tanıma birçok görüntü işleme yöntemleri arasındaki biyometrik tanımlama tekniklerinden biridir. (Pei vd., 2019). Yüz algılama ve hizalama aşamasını takiben, tanımayı gerçekleştirmek için çoklu öznitelik çıkarma yaklaşımları kullanılır. Geleneksel ve derin öğrenme teknikleri en yaygın olanlardır. Çoklu Tanımlayıcı Modeli, Yerel İkili Örüntü (YİÖ), Yönlendirilmiş Gradyanların Histogramı, Gabor filtresi ve Ölçek Değişmez Öznitelik Dönüşümü, öznitelikleri toplamak için el işçiliği kullanılan geleneksel yaklaşımların örnekleridir. Hem güvenilir hem de etkili olan bu işlemlerle yüz tanıma yapılabilir. Ayrıca, bu algoritmalar defalarca değiştirilmiş ve geliştirilmiştir. Örneğin, YİÖ, yüz tanıma verimliliğini artırmak için kullanılmıştır.


Son on yıl boyunca, evrimsel sinir ağları (ESA), görüntü işleme ve bilgisayarlı görüş problemlerini ele almak için en yaygın kullanılan algoritmalarından biri olmuştur. Bir evrimsel sinir ağının gücü, çoklu soyutlama seviyelerinde bir dizi farklı öznitelik haritaları üretebilmesinden doğmaktadır. Diğer çözümlerin çoğu, evrimsel sinir ağlarından olumlu şekilde etkilenmiştir. GoogLeNet ve ResNet dahil olmak üzere birçok ESA yapısı ve derin algoritması vardır. Ayrıca, Oxford Üniversitesi'ndeki bir görsel geometri grubu, evrimsel bir sinir ağı tasarımı olan Deep Face Recognition'ı sunmuştur. Yüz tanımanın üç ana bileşeni yüz algılama, yüz öznitelik çıkarımı ve

tanımlamadır. Yüz algılama, Viola Jones yüz dedektörü (Viola ve Jones, 2004) ve Multi-task Cascade CNN (Zhang vb., 2016) gibi yaygın teknikleri kullanarak görüntülerden bir veya birden fazla yüzü çıkarır. En önemli aşama, yüzün özniteliklerini belirleyen öznitelik çıkarımı iken, tanımlama ise görüntünün kime ait olduğunu belirlemek için yapılır. İlk olarak, yüz algılama: Bu aşamanın amacı, görüntüdeki belirli bir yüzü seçmektir. Yüz tanımda yaygın olarak iki algoritma kullanılır: viola-jones yüz dedektörü ve Multi-task Cascade CNN. Araştırmamız Viola-Jones yüz dedektörünün kontrollü ortamlarda farklı pozlar, aydınlatmalar ve oklüzyonlar gibi koşullar altında iyi çalıştığını, ancak kontrolsüz ortamlarda farklı pozlar, aydınlatmalar ve oklüzyonlar gibi koşullarda sorunlarla karşılaşıldığını göstermiştir. Multi-task Cascade CNN, yüz bölgesini algılamak ve inceden kalına işaretlemek için özel olarak tasarlanmış derin evrimsel ağların üç kademeli yapısını kullanır. Bu çalışmada düşük algılama oranı problemini çözebildiği için Multi-task Cascade CNN kullanılmıştır. İkincisi, öznitelik çıkarma: öznitelik çıkarma, herhangi bir örüntü tanıma algoritmasının birincil amacıdır. Yüz tanımda öznitelik çıkarımı için bir Derin Öğrenme Evrimsel Sinir Ağı kullanılır. Bu, karmaşık bir öznitelik çıkarma yöntemi gerektirmeyen basit bir yöntemdir. Üçüncüsü, tanımlama: tanımlama, bir kişinin yüz görüntüsünün belirli bir sınıfa atamak amacıyla tanınmasıdır. Bu yöntemde öznitelik çıkarıldıktan sonra, bir fotoğraf veya video görüntüsündeki bir yüz mevcut bir yüz veri seti ile karşılaştırılır. Dördüncü olarak, Softmax önündeki tam bağlı katmanın çıktısı ve gerçek sinir ağından çıkarılan özniteliklerle katkı sağlar. Bu sonuç, tüm sınıf etiketleri için olasılık fonksiyonunu temsil etmektedir.

Yüz tanımanın en önemli kısmı öznitelik çıkarma aşamasıdır; çünkü yüz özniteliklerini tanımlamak, herhangi bir yüz tanıma modelinin performansını doğrudan etkilemektedir. Yüz görünümündeki değişikliklere dayanıklı olmalı ve yüz görünümü varyasyonlarında doğru yüz açıklamalarına ulaşabilmelidir. Yüz öznitelik çıkarımı için birçok farklı yöntem vardır. Bu yöntemler üçe ayrılmaktadır: yüz tanıma, yerel tanımlayıcı yöntemler, bütünsel yöntemler ve hibrit yöntemler. Çoğu durumda, bu yöntemler en az üçe ayrılmaktadır.

2.1 Yüz Tanımda Yerel Tanımlayıcı Tabanlı Yöntemler

Yerel teknikler yüz tanıma bağlamında yalnızca belirli yüz özniteliklerini dikkate alır. Yüz ifadelerine, oklüzyonlara ve pozlara daha duyarlı olduğu görülmektedir. Bu yöntemlerin birincil amacı, benzersiz özellikleri ortaya çıkarmaktır. Yerel görünüme dayalı yöntemler, ek bilgi edinmek için burun, ağız ve gözler gibi yüzün önemli kısımlarına odaklanır. Bu yöntemler, piksel yönelimlerini, histogramları ve geometrik özellikleri kullanarak yerel öznitelikleri tanımlar. Görünüme dayalı özniteliklerin çıkarılması, yüzdeki özellikleri tanımlamaya odaklanır. Bu yöntem verimliliği, doğruluğu ve sağlamlığı ile diğerlerinden ayrılmaktadır. Bu teknikle ilgili çoğu yöntem, yerel doku örüntülerinin kodlanmasına dayanır. Bu nedenle, yerel örüntüleri kodladıktan sonra, yüz görüntüsü yüz öznitelik vektörünü belirlemek için bölgelere ayrılır. Geliştirme algoritmaları, yerel örnek seçimi ve öznitelik kodlaması kullanılan tekniklerden bazılarıdır (Ding ve Tao, 2016; Mclaughlin vd., 2016). Yerel tanımlayıcıların çoğu el işçiliği ve teknik uzmanlığa dayanmaktadır. Yerel ikili örüntü (YİÖ), Şekil 2.1'de gösterildiği gibi birkaç yüz tanıma tekniğinden biridir. Ortadaki ikili piksel değerleri, çevresindeki diğer 8 pikselle karşılaştırılır.




Şekil 2.1 Yerel ikili örüntü yöntemi (Ghorbani vd., 2015; Gupta vd., 2022)

YİÖ yaklaşımı, üretilen resim ile veri tabanındaki resim arasındaki benzerlikleri eşleştirmek için kullanılabilir. Bu yöntemde komşu piksellerin değerleri, merkezi resmin değerini azaltır. Yöntem 3x3 piksel matris üzerinde çalışır. Elde edilen değer 0'dan büyük veya 0'a eşitse 1 döndürür, ancak ölçülen değer 0'dan küçükse 0 döndürür. Bunu takiben saat yönünde veya saat yönünün tersine sıralanmış 3x3 matristeki 8 komşu pikselden ikili değerler alınır ve daha sonra merkezi resmin piksel değerini değiştirmek için ondalık forma çevrilir. Ek olarak, ikilileştirme tekniği ışıktaki değişikliklere karşı direnci artırır. Yüz tanımda YİÖ ileri derecede üretken ve

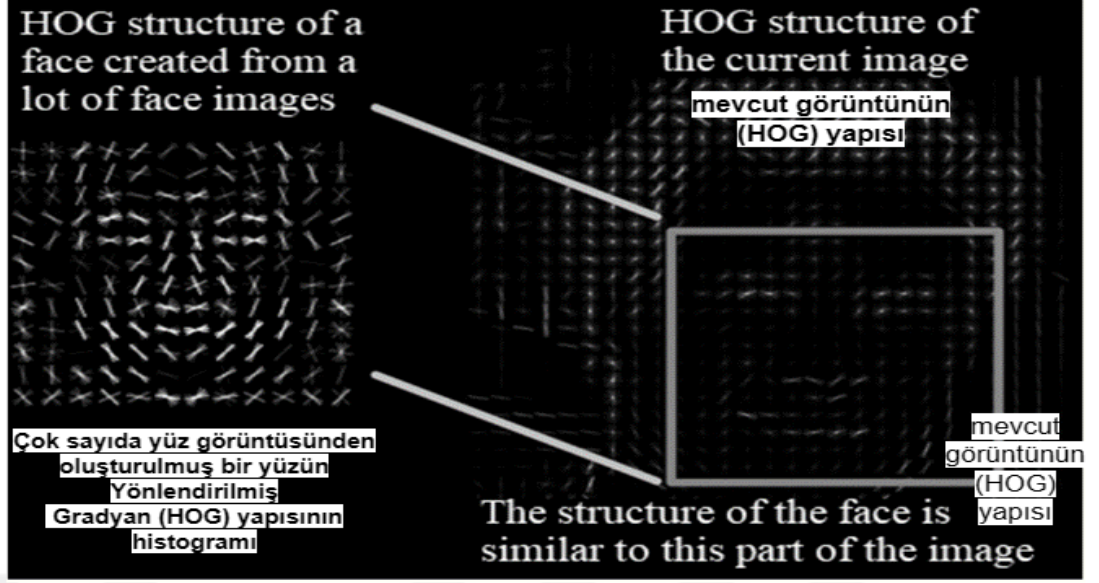
kullanılırdır. Çeşitli YİÖ modifikasyonları, özellikle Yerel Üçlü Örüntüler (YÜÖ) geliştirilmiştir (Song vd., 2022; Zheng vd., 2022).

Bir diğer çok önemli yerel tabanlı yöntem, özellikle doku tabanlı görüntü işlemede (örneğin, sınıflandırma, segmentasyon veya kenar algılama) ve daha da önemlisi yüz tanımda öznelik çıkarmak için yaygın olarak kullanılan Gabor filtreleridir (Barina, 2016). Gabor dalgacıkları, çok ölçekli ve çok yönlü yüz resmi verilerini temsil edecek şekilde tasarlanmıştır. Sonuç olarak, Gabor tabanlı tanımlayıcılar, öznelikleri YİÖ'den ve varyasyonlarından daha yüksek ölçeklerde alabilir. Yerel Faz Niceleme (YFN), başka bir temel özellik tanıımıdır. YFN, her bir yerel yüz resmi parçasından bulanıklığa dayanıklı ikili örüntüler türetir. Sonuç olarak, bulanıklığa dayanıklı yüz tanıma için sıklıkla kullanılmaktadır (Ahonen vd., 2008). YFN tanımlayıcısı, bulanıklığa karşı çok hassas olup, hem bulanık hem de net resimlerde YİÖ'den daha iyi performans gösterir. Lowe, (1999), resim tabanlı eşleştirme ve tanıma için Ölçek Değişmez Öznelik Dönüşümü (*Scale Invariant Feature Transform: SIFT*) adlı bir görüntü tanımlayıcısı geliştirmiştir. Bu tanımlayıcı, diğer görüntü tanımlayıcılarla birlikte, üç boyutlu bir sahnenin farklı görünüşleri arasında nokta eşleştirme ve görünüşsel nesne tanıma dahil olmak üzere çeşitli uygulamalar için bilgisayarlı görüde kullanılır. SIFT tanımlayıcısı, resim alanı döndürmelerine, dönüşümlerine, ölçekleme ötelemelerine ve ayrıca küçük ölçekli perspektif değişikliklerine ve aydınlatma değişikliklerine karşı dayanıklıdır. SIFT tanımlayıcısının, gerçek hayat durumlarında resim karşılaştırma ve nesne tanıma için oldukça faydalı olduğu başarılı bir şekilde gösterilmiştir (Lindeberg, 2012). SIFT tanımlayıcısı, her öznelik noktasının etrafındaki komşulardaki yerel yüz yapılarının kapsamlı bir analiz detayını vermek için görüntü yoğunluklarının yerel gradyan yönü istatistiklerini toplayarak siyah beyaz bir görüntüdeki kilit noktaları tespit etmeye yönelik bir tekniktir. Bu tanımlayıcı, Şekil 2.2'de gösterildiği gibi, çeşitli resimler arasındaki bağıntılı nesneleri eşleştirmek için kullanılmaktadır.



Şekil 2.2 Farklı ifadeler taşıyan yüzlerde eşleşen öznitelikler ve örnek fotoğraflardaki SIFT özellikleri (Luo vd., 2007)

Calonder vd. (2010) tarafından önerilen BRIEF, bir görüntü parçasını ikili bir dizi olarak tanımlamak için sınırlı sayıda yoğunluk farkı testine dayanarak ikili dizileri etkili bir öznitelik noktası tanımlayıcısı olarak kullanır. Dalal ve Triggs (2005) insan vücudu tespiti için şu anda bilgisayarlı görü ve görüntü işlemede en etkili ve yaygın olarak kullanılan tanımlayıcılardan biri olan Yönlendirilmiş Gradyanların Histogramı'nı (YGH) tanıtmıştır. YGH, bir görüntünün bir bölümünde gradyan oryantasyonu oluşumlarını hesaplayan bir görünüm tanımlayıcıdır. YGH, giriş resmini küçük kare hücrelere böler ve ardından Şekil 2.3'te gösterildiği gibi merkez varyasyonlarına dayalı olarak bir gradyan veya kenar yönleri histogramını değerlendirir. Yerel histogramlar, daha doğru sonuçlar elde etmek için kontrasta bağlı olarak normalleştirilmiş olduğundan aydınlatma dalgalanmalarında YGH sabit kalmaktadır.



Şekil 2.3 YGH yapısı ile yüz tanıma (Voronov vd., 2019)

Temel bileşenler analizi (TBA) güncel veri işlemede bilimin hemen her alanında yaygın olarak kullanılan bir yöntemdir (Destefanis vd., 2000; Kurita, 2019). TBA'nın amacı, belirli bir veri setini ifade etmek için en uygun temeli bulmaktır. Bu yeni yöntem, veri tabanındaki gizli yapıyı ortaya çıkarmak ve gürültüyü filtrelemek için tasarlanmıştır. Veri işleme, veri azaltma, özniteliklerin çıkarılması ve görselleştirme teknikleri, bu yöntemin kullanım alanlarına sadece birkaç örnektir. Yüz tanıma görevleri için özniteliklerin çıkarılması için bir yaklaşım önerilmiştir. Burada sunulan yaklaşım, lineer diskriminant analizinin iyi bilinen çerçevesini kullanır ve düzenli olarak kullanılan bir dizi tekniğin genel hali olarak düşünülebilir. Bu yeni teknik, sınıflar arası dağılım matrisinin sıfır uzayını güvenli bir şekilde ortadan kaldırmak için D-LDA'nın yeni bir varyasyonunu, ardından elde edilen D-LDA öznitelik uzayının ayırt edici gücünü geliştirmek için kesirli adım LDA şemasını kullanır (Lu vd., 2003).

2.2 Yerel Tanımlayıcı ile İlgili Çalışmalar

Yüz tanıma, günümüzde hemen hemen her endüstri alanındaki geniş uygulama yelpazesi nedeniyle en çok araştırılan konular arasındadır; ancak farklı veri tabanlarında mükemmele yakın doğruluk elde edebilen bir algoritma mevcut değildir (Goel, 2022). Yüz tanımanın en önemli görevi, farklı yüzleri ayırt etmeye yardımcı olan öznitelik çıkarmadır. Çıkarılan özniteliklerin kalitesi, biyometrik sistemlerin ve fotoğraf sınıflandırma yöntemlerinin doğruluğunu etkiler (Norouzi, 2022). Boyut

indirgeme (*dimensionality reduction*: DR) yaklaşımı, görüntünün ayırt edici özelliklerini çıkarmak için yüz tanıma yaygın olarak kullanılır. Yüz pozisyonları, tutumlar ve aydınlatmadaki farklılıklar performans üzerinde önemli bir etkiye sahiptir (Chen ve Zhou, 2022). Aydınlatma farklılıkları, oklüzyon, yüz ifadesi ve diğer faktörler nedeniyle yüz tanıma zor bir süreç olabilir (Zhang vd., 2021). Görüntülerde zengin arka plan ve çok sayıda özellik bulunması da yüz tanımayı zorlaştırır. Bu nedenle, resim özellikleri uygun şekilde elde edilmeli ve anlaşılmalıdır. İyi bir görüntü tanımlayıcısı geliştirmek zordur. Alınan öznitelik vektörlerinin boyutu, örüntü tanımadaki en zorlayıcı konulardan biridir, bu nedenle öznitelik seçimi gerekli hale gelir. Biyometri zamanla bozulduğundan, öznitelik seçimi biyometride önemli ve gerekli bir aşamadır (Gavel ve Mehta, 2021). %80'lik ortalamanın üzerindeki doğruluk, yüksek bir yüz tanıma yeteneği gösterir (Shukla vd., 2021).

Yerel tanımlayıcılar, yüz tanıma gibi çeşitli uygulamalarda elde edilen başarı nedeniyle araştırmacılardan büyük ilgi görmüştür. Karanwal ve Diwakar (2021b) 3 x 3 piksellik bir çerçevede iki ana grubun her bir ortogonal konumu için poz, ifade ve ışık varyasyonlarına yönelik olarak Ortogonal Farklılık-Yerel İkili Örüntü (*Orthogonal Difference-Local Binary Pattern* OD-LBP) tanımlayıcısını önermiştir. 3 gri seviye varyasyonları, en yakın iki komşunun ve merkez pikselin karşılık gelen ortogonal değerden çıkarılmasıyla hesaplanır. Yale yüz veri tabanındaki OD-LBP %76,66 gibi oldukça iyi bir doğruluk oranı yakalamıştır.

Karanwal ve Diwakar (2021a) kontrolsüz durumlar için NCDB-LBP kullanımını önermektedir. NCDB-LBP'nin temel prensibi hem saat yönünün tersine (*anticlockwise*: ac) hem de saat yönünde (*clockwise*: c) dönüşlerde üç piksel çerçevesinde sunulmuştur. Bu iki tanımlayıcının adları NCDB-LBPac ve NCDB-LBPc'dir. Yale Face veritabanındaki sonuç, Eğitim=4; %99,16 ve %98,75'tir. Genişletilmiş Yale B yüz veritabanında Train=6; %99,23 ve %99,23 olarak bulunmuştur. Sonuçların en iyi doğruluğa dayalı olmasıyla birlikte bu performans oldukça iyidir.

Karanwal (2021) yaptığı deneyle çeşitli konum, aydınlatma, ifade ve oklüzyon koşulları altında birçok son teknoloji tanımlayıcıyı karşılaştırmıştır. Sonuçlar en iyi

model performansına ve doğruluğuna göre özetlenmiştir. En iyi doğruluk oranına Yerel doku operatörü bileşik yerel ikili örüntü (*compound local binary pattern: CLBP*), (Ahmed vd., 2011) ile ulaşılırken Yale Face veri tabanı için Eğitim=4, %100; EYB yüz veri tabanında %96,88; Eğitim=20 olarak gerçekleşmiştir. İki veri tabanındaki en iyi sınıflandırma doğruluğunun 39 test sonucunda elde edildiği açıktır.

Bu bölümde yeni çoklu tanımlayıcılar önerilmektedir. Tanımlayıcının geliştirilmesi öznitelikleri çıkarmak için çeşitli tanımlayıcılar kullanarak, her tanımlayıcı için histogramı hesaplayarak ve bir çift öznitelik vektörü üreterek, ardından öznitelik çiftini birleştirip yüz görüntüsü için son bir öznitelik vektörü oluşturarak mükemmel yüz tanıma doğruluğunu elde etmek için Yerel İkili Örüntü denklemi ile ispatlanmış matematiksel teoriye dayanmaktadır. Çoklu tanımlayıcılar için önerilen yüz tanıma modelinin değerlendirilmesi için, yeni modelin de yerel ikili örüntü ile geliştirilmesinin iki sebebi vardır. Birincisi, çoklu tanımlayıcı ve yerel ikili örüntü arasındaki önemli performans farkını göstermektir. İkincisi, yüz tanıma sistemleri için mümkün olan en az karmaşıklıkla mükemmel performans elde etmektir. Bu bölümün geri kalanı aşağıdaki gibi düzenlenmiştir. 2. kısıma giriş, yöntem, geliştirme ve destek vektör makinesini kapsar. 3. kısım, önerilen yüz tanıma yaklaşımını ve değerlendirme matrislerini açıklamaktadır. 4. kısımda veri tabanları ile deneysel sonuçlar tartışılmaktadır. 5. Kısımda bölümün özeti sunulmaktadır.

Bu bölümde, iki çoklu tanımlayıcının birleşmesi ve destek vektör makinesi yöntemi ayrıntılı olarak önerilmiştir. Bu çalışmada algoritmaların doğruluğunu değerlendirmeye yönelik veri çeşitliliğini sağlamak için bilinen veritabanlarına odaklanılmıştır. Her veritabanı farklı sayıda katılımcı içerir. Her katılımcıya sınıf denir ve C (*class*) ile gösterilir. Her sınıfta farklı sayıda örnek vardır ve S (*sample*) ile gösterilir. Veri tabanının toplam örnek görüntü sayısı sınıf sayısı ile örnek sayısı çarpılarak hesaplanır; ($C \times S$) ile gösterilir. Tezde kullanılan veri tabanları kırılmış ve 128x128 piksel olarak yeniden boyutlandırılmıştır.

Önceki çalışmalar, kontrolsüz ortamlar (özellikle aydınlatma değişiklikleri) için yüz tanıma zorluklarını ele almıştır. Bu bölümde ise, bu özellikleri uygun şekilde entegre ederek önerilen modeli önemli ölçüde geliştirecek olan yüz tanıma için yeni öznitelik


çıkarımı önerilmektedir. Farklı veri setleri kullanarak gerçek performansı değerlendirmek için sonuçlar beş çapraz doğrulamaya dayalı olarak kaydedilmiştir.

2.3 Yüz Tanımda Derin Öğrenme Tabanlı Yöntemler

El İşçiliği kullanılan tanımlayıcılarda yüz tanıma için iyi teknikler yöntemler ortaya konulmuştur, çünkü yerel tanımlayıcı tabanlı yaklaşımlar sıkı mimariler içerir. Öte yandan bu yöntem soyut ve doğrusal olmayan bilgileri yakalamada yetersizdir ve deneysel doğrulamanın yanı sıra önemli ölçüde uzmanlık bilgisi gerektirir. Derin öğrenmeye dayalı teknikler ise hiyerarşi ve temsilden yararlanır.

Makine öğrenmesi, talimat verilmeden örnek verileri kullanarak tahminler yapan bir model oluşturur. Özellikle veriler net olmadığında ve görev zor olduğunda etkilidir, bu da bir bilgisayar bilimcisinin öğrenme veya adaptasyon olmadan zorlukları çözmek için özel bir yöntem bulmasını zorlaştırır (Pandita, 2021).

Derin öğrenme tabanlı algoritmalar, biyometrik teknolojiyi önemli ölçüde geliştirmiştir. Eğitim adımı tamamlandıktan sonra, yüz girdisinden bağımsız olarak tüm evrişimsel sinir ağı tabanlı yüz tanıma sistemleri boyunca öznetelik çıkarma için evrişimsel çekirdekler yerleştirilir (Han vd., 2022). Şekil 2.4, klasik makine öğrenmesi algoritmalarının performansının, küçük oranlarda eğitim veri tabanları için açıkça diğerlerinden üstün olduğunu göstermektedir. Verilerin boyutu belirli bir eşik değerin üzerine çıktığında, klasik makine öğrenmesi algoritmalarının performansı sabit kalır. Derin öğrenme algoritmaları ise veri miktarı arttıkça performanslarını artırmıştır (Alom vd., 2018). Yüz tanıma, çok sayıda veri seti nedeniyle en zorlu görevlerden biri olarak kabul edilir. Şekil 2.4'te görüldüğü gibi, Yapay Sinir Ağları (YSA) verilerin işlenmesinde tanıma performansı açısından oldukça başarılıdır (Mohamed vd., 2021; Walczak, 2018). YSA araştırmaları, beynin biyolojik bir modeline, özellikle beyin nöronlarının biyoelektrik aktivitesine dayalı makine öğrenimi algoritmaları geliştirmeyi amaçlamaktadır.



Şekil 2.4 Derin öğrenmenin performansı (Alom vd., 2018)

Derin öğrenme teknikleri, giriş verilerinin hiyerarşik özniteliklerini üreten bir dizi makine öğrenme tekniğidir. Her katmanın veri işleme genellikle geri beslemeli yöntemler kullanılarak öğretilir (Georgiou vd., 2020). Yakın tarihli bir araştırmaya göre, Evrimsel Sinir Ağlarını kullanan derin öğrenme, son zamanlarda bilgisayarlı görü alanında başarılı olmuştur. Yüzleri algılamak bu yöntemin başarılarından biridir. ESA, çok sayıda eğitim verisinden karmaşık görsel farklılıkları temsil eden öznitelikleri otomatik olarak öğrenebildiği için önceki yaklaşımlardan daha iyi performans gösterir (Saragih ve To, 2022). Bir evrimsel sinir ağı, birçok evrim katmanından, ortaklama katmanlarından ve etkileşim fonksiyonlarından oluşur. Her katman tipik olarak bir dizi farklı evrimsel çekirdeğe, doğrusal olmayan bir etkileşim fonksiyonuna ve muhtemelen beklenen çıktının boyutsallığını azaltmak için bir ortaklama işlevine sahip olmalıdır. Evrimsel Sinir Ağları, son yıllarda yüz tanıma için en etkili derin öğrenme yöntemi olarak görünmektedir. ESAnın yüz tanıma için ilk kullanımı önceki yüzyıla kadar uzanır. Ayrıca, ESA tabanlı yöntemler, çok sayıda model parametresi içerdiği ve eğitim verisinin eksikliği nedeniyle karmaşık olduğundan on yıldan fazla bir süredir ESA tabanlı yöntemlere yönelik bilimsel ilgi azdı. Bununla birlikte, ESA model yapısındaki büyük ilerlemelerin ve kullanılabilir verilerin çoğalmasıyla ESA'lar derin öğrenmenin özelliklerini içeren Tablo 2.1'de gösterildiği gibi, yüksek düzeyde ayırt edilebilir ve genellenebilir betimlemeler


geliştirebilecek şekilde ayarlanabilmektedir. Öyle ki, geçtiğimiz iki yıl boyunca ESA tabanlı algoritmalar yüz tanıma alanına öncülük etmiştir (McLaughlin vd., 2016).

Tablo 2.1 Derin öğrenmenin özellikleri

Derin Öğrenmenin Özellikleri	
Evrensel Öğrenme	Her uygulama alanında kullanılabilir olmasından kaynaklanır.
Doğal Değişimlere Dayanıklılık	Otomatik olarak öğrenilen görevlere en uygun özelliktir. Sonuç olarak, verideki doğal değişimlere karşı otomatik olarak eğitilmiştir.
Genellenebilirlik	Derin öğrenme yöntemi birçok farklı uygulama ve veri seti ile kullanılabilir.
Ölçeklenebilirlik	Derin öğrenme yöntemi oldukça genişletilebilirdir.


En yaygın ve yüz tanımada en etkili derin öğrenme yöntemlerinden bazıları şunlardır: AlexNet (Krizhevsky vd., 2012), SqueezeNet (Iandola vd., 2016; Koonce, 2021), VGG-16 (Simonyan ve Zisserman, 2014), Resnet (He vd., 2016), facenet (Schroff vd., 2015) ve Densely Convolutional Networks (Huang vd., 2017). AlexNet ağı, ilk beşi evrişimsel ve son üçü tam bağlı olan sekiz ağırlıklı katmana sahiptir. "Squeeze" ve "expand" katmanları, SqueezeNet yapısını oluşturur. Squeeze evrişim katmanında yalnızca bir filtre kullanılır. Bunlar, bir uzatma katmanında 1x1 ve 3x3 evrişim filtrelerinin bir kombinasyonu aracılığıyla gönderilir. Simonyan ve Zisserman (2015)'ın VGG ağlarını ortaya koyması bu alandaki ilk önemli çabalardan biridir. Çalışmalarında küçük evrişimsel çekirdekler (3x3) kullanılarak daha derin ağların eğitilebileceğini göstermektedirler. 11; 13; 16 ve 19 ağırlıklı katmanlı yapılar geliştirmişlerdir.

Evrişimsel sinir ağı en temel derin öğrenme yöntemlerinden biridir. ESA'nın gücü, görüntüden özel ayırt edici öznitelikleri öğrenme yeteneğidir. Yüz tanıma için en iyi bilinen son teknoloji ESA mimarisi, Şekil 2.5'te görülen VGG yüz modelidir. Şekil 8'deki VGG-yüz modeli 13 evrişim katmanı, 5 maksimum havuzlama katmanı ve 3 tam bağlı katman ve ardından softmax katmanından oluşmaktadır. Her evrişim için filtre boyutu 3X3'tür.



Şekil 2.5 Derin öğrenme VGG- yüz tanıma modeli (Mangasarian ve Musicant, 2001; Simonyan ve Zisserman, 2014)

Sinir ağlarının en derin noktasındaki en büyük kısıtlama, gradyanların azalmasıdır. Bu sorunu çözmek için, otoyol ağları ve artık ağlar (ResNet), verileri bir katmandan bir veya daha fazla düzey daha derine göndermek için "atlama (skip)" veya "kısayol (shortcut)" bağlantılarını kullanır. DenseNet, önceki tüm katmanları sinir ağına girdi olarak kullanarak bu konsepti bir adım daha ileri taşımıştır. ResNet ve ResBlock yapısal blokları Şekil 2.6'da gösterilmiştir.



Şekil 2.6 ResNet, a) orijinal artık yapı b) ön-aktivasyonlu artık yapı

Daha derin ağların eğitime yardımcı olan atlama bağlantılarının yanı sıra, ağ kalitesini iyileştirmeye yönelik çeşitli yöntemler de araştırılmıştır. Min Lin, Qiang

Chen (2014) Ağ içinde Ağ (*network in network*: NiN) mimarisini önermiştir. Çalışmalarındaki doğrusal evrişimsel düğümleri küçük çok katmanlı algılayıcılarla (*multilayer perceptrons*: MLP) değiştirerek ağa bir katmandaki doğrusal olmayan eşlemeleri öğrenme kapasitesi kazandırılmıştır. Lee vd. (2015) doğrudan ağın gizli katmanlarına ikincil denetim sinyalleri gönderen derin denetimli ağları (*deeply supervised networks*: DSN) önermiştir. Liu vd. (2018) sınıflandırma ve başka görevler için son kararın daha derin katmanlardan gelen bilgilerin yanı sıra son katmandaki bilgileri kullanarak verildiği alternatif bir yöntem araştırmışlardır. Araştırmacılar bunu, daha derin katmanlardan gelen alt düzey girdileri üst katmanın yüksek düzeyli bilgileriyle birleştirmek ve daha uygun bir karar oluşturmak için yerel bağlı (LC) katmanları kullanan evrişimsel füzyon ağları (*convolutional fusion network*: CFN) ile başarmıştır.

Derin öğrenme, insan beyninin veri analizindeki işleyişini taklit eden ve karar vermede kullanılacak yapılar oluşturan bir yapay zeka yapısıdır. Makine öğrenmesi, etiketlenmemiş verilerden veya yanlış etiketlenmiş verilerden denetimsiz öğrenme yapabilen ağlara sahip, derin sinirsel öğrenme veya derin sinir ağı olarak da bilin bir yapay zeka uygulamasıdır.


Derin görüntü öğrenimindeki gelişmeler, son yıllarda yüz tanıma üzerinde büyük bir etkiye sahip olmuştur. İlk çalışmalardaki karşılaştırmalı kayıp (*contrastive loss*), üçlü kayıp (*triplet loss*) ve ceza açısız marj kayıpları (*penalty angular-margin losses*) gibi kayıplar, metrik öğrenmeye dayalı kayıplara dayanmaktadır. Eğitim için gereken yüz üçlülerinin sayısındaki büyük artış nedeniyle araştırma odağı sınıflandırmaya dayalı yöntemlere yönelmiştir. Bu yöntemler genellikle softmax'a dayanır ve eğitim sırasında önceki katman görünmeyen yüzler için bir öznitelik çıkarıcı görevi görürken kapalı bir kimlik kümesi üzerinde sınıflandırma yapmaya çalışır (Terhörst vd., 2021).

2.4 Derin Öğrenme İle İlgili Çalışmalar

Sinir ağları ve diğer derin yapılar bu alandaki en yaygın terimlerdir. Derin öğrenme yöntemleri, son zamanlarda çok çeşitli alanlarda çok başarılı sonuçlar elde etmiştir (Buczkowski vd., 2018). Makine öğrenmesinin derin öğrenme adı verilen bir dalı

vardır. Son yıllarda, derin öğrenme, öznitelik çıkarma, konuşma tanıma, resimli metin analizi ve diğer alanlarda önemli faydalar sağlamıştır (Yu ve Pei, 2021). Bu algoritmalar tipik olarak belirli görevler için geleneksel öznitelik mimarisi gerektirmez. Bu yöntemlerin en faydalı özelliği, el işçiliği ile tasarlanmış ek bileşenler veya zaman alıcı öznitelik mühendisliği kullanmadan etkili bir şekilde performans gösterebilmeleridir. Ayrıca, çeşitli yaygın problemlerin üstesinden gelmek için birleşik bir tasarım ve öğrenme algoritmasının kullanılabileceği gösterilmiştir. ResNet (Sangeetha ve Prasad, 2006), DenseNet (Huang vd., 2017) ve AlexNet (Iandola vd., 2016) gibi birçok bilinen ESA mimarisi ve derin model vardır. Ayrıca, Oxford Üniversitesi'ndeki görsel geometri grubu tarafından geliştirilen Derin Yüz Tanıma (Deep Face Recognition) (Parkhi vd., 2015) adı verilen evrimsel bir sinir ağı mimarisi kayda değer bir performans sunmuştur.

Her ikisi de derin bir evrimsel tasarım modeli kullanan iki çalışma, bu bölümde oluşturulan ESA mimarisini etkilemiştir (Parkhi vd., 2015). Çeşitli değişiklikler ve iyileştirmeler ile geliştirilen ESA modellerimiz, performansta gözle görülür bir artış sunmaktadır. VGG, derin ağı tasarlamış ve farklı veri tabanlarında son teknoloji ürünleriyle karşılaştırılabilir sonuçlar elde etmiştir. Tablo 2.2. Her Katman için Derin Yüz Parametrelerini ve Şekil 2.7, 3x3 filtre boyutuna sahip 13 evrim katmanından ve her katmanın ardından bir Düzleştirilmiş Doğrusal Birim (ReLU) içeren derin yüz mimarisini göstermektedir. İki ve üç tam bağlı katmanın kaydırma (*stride*) ile takip ettiği 5 maksimum ortaklama katmanı vardır.



Şekil 2.7 Derin öğrenme VGG16 yüz mimarisi

Tablo 2.2 Her katman için derin yüz parametreleri

Katman Adı	Girdi Boyutu	Filtre Sayısı	Dolgulama (<i>padding</i>), Kaydırma (<i>stride</i>), Filtre Boyutu
Conv1	224 x 224	64	1; 1; 3
Conv2	224 x 224	64	1; 1; 3
Max Pooling1	224 x 224	-	0; 2; -
Conv3	112 x 112	128	1; 1; 3
Conv4	112 x 112	128	1; 1; 3
Max Pooling2	112 x 112	-	0; 2; -
Conv5	56 x 56	256	1; 1; 3
Conv6	56 x 56	256	1; 1; 3
Conv7	56 x 56	256	1; 1; 3
Max Pooling3	56 x 56	-	0; 2; -
Conv8	28 x 28	512	1; 1; 3
Conv9	28 x 28	512	1; 1; 3
Conv10	28 x 28	512	1; 1; 3
Max Pooling4	28 x 28	-	0; 2; -
Conv11	14 x 14	512	1; 1; 3
Conv12	14 x 28	512	1; 1; 3
Conv13	14 x 14	512	1; 1; 3
Max Pooling5	28 x 28	-	0; 2; -
Output	7x7		
Fully connected	4096		
Dropout	0,5		
Fully connected	4096		
Dropout	0,5		
Fully connected	N classes		
Softmax	N classes		

Daha derin ağlar yakınsamaya başlarken, ağ derinliği arttıkça bir bozulma sorunu ortaya çıkar, doğruluk doygun hale gelir ve hızla bozulur. Modelin performansı, daha derin ağların kullanılmasıyla düşer. Bu soruna bir çözüm bulmak için Derin Artık Öğrenme (*Deep Residual Learning*) yöntemi kullanılır. Resnet makalesinde açıklandığı gibi (He vd., 2016), bloklar iki kategoriye ayrılır: kimlik blokları ve evrişim blokları. Artık öğrenmeyi uygulayan temel yapı denklem 2.1'de verilmiştir.

$$y = F(x, \{W_i\}) + x \quad (2.1)$$

The diagram illustrates the forward pass of a neural network layer with two different architectures, labeled 'a' and 'b'.

Architecture a:

- Input X_i is fed into a summation node (+).
- The input X_i is also fed into a sequence of operations: **Ağırlık** (Weight), **Yığın Normalleştirme** (Batch Normalization), **Doğrultulmuş Doğrusal Birimin** (Rectified Linear Unit), **Ağırlık** (Weight), and **Yığın Normalleştirme** (Batch Normalization).
- The output of this sequence is fed into the summation node (+).
- The output of the summation node is the **Doğrultulmuş Doğrusal Birimin** (Rectified Linear Unit).
- The final output is X_{i+1} .


Architecture b:

- Input X_i is fed into a summation node (+).
- The input X_i is also fed into a sequence of operations: **Yığın Normalleştirme** (Batch Normalization), **Doğrultulmuş Doğrusal Birimin** (Rectified Linear Unit), **Ağırlık** (Weight), **Yığın Normalleştirme** (Batch Normalization), **Doğrultulmuş Doğrusal Birimin** (Rectified Linear Unit), and **Ağırlık** (Weight).
- The output of this sequence is fed into the summation node (+).
- The output of the summation node is the **Doğrultulmuş Doğrusal Birimin** (Rectified Linear Unit).
- The final output is X_{i+1} .

Diagram illustrating the 34-layer residual network architecture. The network starts with an 'image' input, followed by a '7x7 conv, 64, /2' layer. This is followed by a 'pool, /2' layer. The main body consists of 18 residual blocks. The first 6 blocks are '3x3 conv, 64' layers. The next 6 blocks are '3x3 conv, 128, /2' layers. The final 6 blocks are '3x3 conv, 128' layers. The network ends with an 'avg pool' layer and a 'fc, 1000' layer. Arrows indicate the flow of data between layers, with dashed arrows showing skip connections for residual blocks.

30

Daha açıklayıcı olmak gerekirse, araştırmacılar, erken modellerin ortaya koyduğu performansa bakmaksızın bu alanda daha etkili modeller geliştirmeye devam etmiştir Huang vd. (2017). Artık ağ bağlantılarına dayalı olarak geliştirilen yeni bir evrişimsel ağ yapısı olan yoğun bir evrişimsel ağ önermiştir. Bu ağ aynı öznitelik haritası boyutuna sahip herhangi iki katman arasında doğrudan bağlantı kurar ve Şekil 2.10'te DenseNets'in tipik olarak performans bozulması veya aşırı öğrenme belirtisi olmaksızın istikrarlı performans iyileştirmesini sağladığı bulunmuştur. DenseNets, parametreleri daha etkin kullanmasının bir sonucu olarak aşırı öğrenmeye daha az eğilimlidir.



Şekil 2.10 Herhangi iki katman arasında doğrudan bağlantı kuran bir yoğun ağ (Huang vd., 2017)

Değerlendirilen mimarilerin iyi performans gösterdiği birkaç umut verici araştırma alanı tanımlanmıştır. Sonuç olarak, farklı ve gelişmiş bilgi alanlarını teşvik etmek amacıyla literatürde çok sayıda uygulama alanı için çalışmalar yapılmaktadır.

Gasparin vd. (2022)'nin ortaya koyduğu DarkNet-19, 19 katmanlı bir derin evrişimsel sinir ağıdır. Bu ağ büyük ölçüde filtreler kullanır ve VGG mimarisine eşdeğer olan her ortaklama aşamasından sonra kanal sayısını iki katına çıkarır. Ağ içinde Ağa (*Network in Network*: NIN) benzer şekilde, evrişimler arasındaki öznitelik gösterimini baskılamak için tahminler ve filtreler oluşturmak için küresel ortalama ortalamayı kullanır.

Daha derin bir anlayış için, uzmanlar önceki modellerin sunduğu verimliliğe rağmen bu alanda çalışmaya devam ederek belirli veri tabanları üzerinde birbirinden daha başarılı modeller oluşturmaya çalışmışlardır. Zeng vd. (2021) büyük ölçekli poz değişiklikleri, aydınlatma koşulları, yetersiz çözünürlük, çeşitli yüz ifadeleri ve oklüzon gibi problemler içeren yüz tanıma algoritmalarının hala kabul edilebilir olmaktan uzak olduğunu bildirmiştir.

Bir ESA'nın alt katmanları tarafından elde edilen özellikler büyük ölçüde eğitim setine bağlı olduğundan, veri seti seçimine çok özen gösterilmelidir. Daha iyi temsil eden bir eğitim veri seti seçmek için tipik olarak binlerce görüntü içeren daha büyük eğitim setleri oluşturma veya seçme süreci kullanılır. Bu nedenle, bu yaklaşım pratik olmaktan uzaktır çünkü eğitim seti için doğru görüntüleri seçmek için önemli ölçüde emek ve eğitimi gerçekleştirmek için önemli miktarda bilgi işlem kaynağı gerektirir. Son zamanlarda, derin öğrenme araştırmacıları gereksiz değişken sorunuyla oldukça ilgilenmeye başlamıştır. Eğitim verilerini tam olarak uydurmada etkili olmasına rağmen, gereksiz değişken içeren sinir ağları, geleneksel öğrenme teorisinin tahminlerinin aksine test verilerinde sıklıkla yeterince iyi performans göstermiştir.

Bu tezde, öznetelik çıkarımı için derin öğrenme tabanlı evrimsel bir sinir ağı kullanılmıştır. Bu, karmaşık öznetelik çıkarma ve el işçiliği yöntemleri gerektirmeyen bir yöntemdir. Yüz tanıma, tanımlama ve kimlik doğrulama için yaygın olarak kullanılmaktadır. Bu bölümün amacı, yüz tanıma için etkin bir şekilde kullanılabilen yeni bir ESA mimarisi geliştirmektir. Önerilen ESA modelini sonuçlar, tartışma, performans değerlendirme ve karşılaştırma ve sonuç takip etmektedir.

2.5 Yüz Tanıma ve Yoklama ile İlgili Çalışmalar


Yüz, vücudun bir bireyi diğerinden ayırt etmek için en çok kullanılan kısımdır ve bilgisayarlı görü, güvenlik sistemleri (örüntü tanıma), insan makine etkileşimi ve görüntü analizi gibi birçok farklı alanda uygulanan temel bir biyometri yöntemidir (Devan vd., 2017). Uzaktan eğitim, eğitim ortamına uyum sağlayarak yüz yüze eğitimi destekleyici bir görev yapan temel bir öğrenme yaklaşımıdır (Aydın ve Erol, 2021). Devamlılık sistemi uygulaması, insan yüzü tanıma sisteminin uygulamalarından biridir. Bir yüz veritabanı, bir kişinin yüzünü tanımlamak ve tanımak için bir devamlılık sistemi tarafından kullanılır (Winarno vd., 2021).

Mevcut tanıma algoritmalarının orta düzeyde bir zeka düzeyine ulaşmış olmasına rağmen, yüz tanımanın gelişimi hala görüntü alımı sürecindeki farklı uygulamalar tarafından belirlenen koşullarla sınırlıdır (Gawande vd., 2022; Shreekumar vd., 2022). Bir derste geleneksel yöntem kullanılarak büyük öğrenci gruplarını ele almak zordur.

Sisteme veri eklenmesi zaman gerektirdiğinden ve yüksek bir hata olasılığına sahip olduğundan bu yöntem tavsiye edilmez (SAI vd., 2021). Uzaktan öğretimde eğitimcilerin karşılaştığı sorunlardan biri, çevrimiçi öğretimin öğretim ve değerlendirme gibi farklı aşamalarında öğrenenlerin gerçekliğinin doğrulanmasıdır. Öğrenenlerin doğrulanması, tanıma teknolojileri ile yapılmaktadır. Birçok uzaktan eğitim sisteminde, katılımcının gerçek bir kişi olup olmadığını veya derse aktif olarak devam edip etmediğini tespit etmek mümkün değildir (Özdemir ve Uğur, 2021a). Uzaktan eğitimi daha güvenli ve güvenilir kılmak için Zhao ve Ye (2010) iki boyutlu bir hidden Markov model (P2D-HMM) kullanan, böylece uzaktan eğitimde öğretim kalitesini artıran bir yüz tanıma yöntemi sunmaktadır. HMM modeli genellikle, daha kararlı hale getirmek için aynı birey için birden fazla farklı yüz ifadesi ve resim örneklerinin hareketleri ile örnekleme yoluyla oluşturulan görüntüler kullanılarak gözlemlenen değer dizilerini eğitmek için kullanılır. Her deney için 30 fotoğraf çeşitli pozisyon, ifade ve aydınlatma varyasyonlarıyla değerlendirilmiştir. Tanınma oranları sırasıyla yüzde 90; yüzde 92,6; yüzde 91,8 ve yüzde 96,3 olup, ortalama yüzde 92,7 olarak hesaplanmaktadır.

Özdemir ve Uğur (2021b) öğrencilerin derse katılımlarını değerlendirmek için görüntü işleme algoritmalarının uygulanmasının yanı sıra uzaktan eğitimde yüz tanıma kullanan bir tasarım modeli konsepti önermiştir. Geliştirilen sistemin uygulanması halinde öğrenenlerin katılım oranları değerlendirilecektir. Sonuçlar, en önemli sorunun, yüz tanıma algoritmalarının zayıf olması veya görüntü alanındaki ışık sapmaları nedeniyle tanıma süreçlerinde düşük başarı oranı (%80-85) olduğunu göstermiştir (Özdemir ve Uğur, 2021a).

Şekil 2.11, yüz tanımada hataların azaltılması ve sistemdeki tanıma oranını iyileştirilmesi gereken önemli durumları göstermektedir.



Şekil 2.11 Yüz tanımanın başarıyla uygulanabilmesi için temel durumlar (Ozdemir ve Ugur, 2021a).

Zainuddin ve Laswi, (2017) bu çalışmada kullanılan yüz tanıma yöntemi olan (LDA) bir Lineer Diskriminant Analizini ortaya koymuştur. Bu yöntemi kullanan platformlar, durumların yüzde 93'ünde doğrulanmış kişileri tanıyabilmektedir. İlgili çalışmalar, uzaktan eğitimde yüz tanımayı iyileştirme tekniklerinden ziyade yüz tanıma uygulamasına odaklanılarak ve geleneksel yöntemler kullanılarak tamamlanmıştır. Bu bölüm, uzaktan eğitim ve yüz tanıma yoklamaya odaklanmaktadır. Tartışılan önceki yöntemler, stratejiler ve algoritmalar, aydınlatma değişikliği, bozulma, boyut ve tek bir görüntüde poz gibi yüz tanımanın doğruluğunu etkileyen zorlukları bütün olarak ele almamıştır. Yüz tanımanın uzaktan öğrenmeyi ve tüm eğitim sürecini doğrudan destekleyebilecek değerli bir biyometrik teknoloji olduğuna inanılmaktadır. Bu bölümün katkıları, güvenilir ve doğru performans elde etmek için birden fazla yöntem kullanarak yüz tanıma ve yoklama için farklı yeni modeller kullanmak, önerilen modelin tüm yapısını test etmek ve eğitmek ve sistemin genel olarak tanınmasını ve kaydını kontrol etmek için farklı yöntemler uygulamaktır.

3. KAVRAMSAL ÇERÇEVE

Bu bölümün temel amacı, yüz tanıma da yeni öznitelik çıkarma yöntemleri geliştirmek için kullanılan derin öğrenmedeki temel kavram ve teknikleri açıklamaktır.

3.1 Yüz Tanıma da Derin Evrişimsel Sinir Ağları

Derin öğrenme, yüz tanıma ile ilgili birçok zorluğu ortadan kaldırmaya yardımcı olmaktadır. Ayrıca, derin öğrenmenin, yüzün daha fazla özniteliğini otomatik olarak öğrenen ve genellenebilirliği yüksek bir modelin tasarımında kullanılabileceği düşünülmektedir. Derin öğrenme ve derin evrişimsel sinir ağları alanında doğru yönergeler ve belirsizliği azaltacak ayrıntılar sağlamak için derin bir analiz ve araştırma gerçekleştirilmiştir. Böylece, birçok uygulamada kullanılabilecek modellerin geliştirilmesi mümkün olmuştur.

Derin öğrenme eğitim alanında birçok problem ve çeşitli veri boyutları için, özellikle denetimli öğrenme bağlamında karşılaşılan yüksek boyutlu ve karmaşık problemler için etkili bir çözüm haline gelmiştir (Balas vd., 2019). Önceki çalışmalarda derin öğrenme modellerinin raporlanan performansları laboratuvar koşullarıyla sınırlıdır. Araştırma ve uygulamalar arasında bir uyumsuzluk bulunmaktadır. Bu nedenle, bu çalışmada yüz tanıma zorluklarını ele almak için yeni bir derin öğrenme modeli oluşturulmuştur. Bu bölümde, yüz tanımayı geliştirmek için yeni ama oldukça verimli bir derin öğrenme modeli sunulmaktadır.

Derin evrişimsel sinir ağlarındaki ilerlemeler sonucunda yüz tanıma algoritmalarının sayısı hızlı bir şekilde artmıştır. Otomatik yüz tanıma, kişisel elektronik eşyalar, kamu güvenliği, erişim kontrolü, güvenlik ve pazarlama dahil olmak üzere çeşitli amaçlar için kullanılır. Yüz tanıma algoritmaları önden çekilmiş görüntülerde oldukça iyi bir doğruluk elde etse de, aydınlatma, ifade ve konumda büyük değişiklikler içeren koşullarda sınırlı işleve sahiptir. Yüz tanıma teknolojisi, bilgisayarlı görü ve özellikle yapay zeka ve derin öğrenme teknolojilerindeki gelişmeler sayesinde son yirmi yılda önemli ölçüde aşama kaydetmiştir. Yüz biyometrisi ise karmaşık arka plan.

aydınlatma, yüzün konumu ve ifadesi gibi konularda zorluklarla karşılaşmaya devam etmektedir.

Bu bölümün geri kalanında, farklı mimariler kullanan derin öğrenme modellerine yer verilecek ve derin öğrenme modelleri ve tanımda iyileştirmeler yapmak için yakın zamanda geliştirilen yöntemlere dayalı olarak yüz tanıma için yeni bir Inception mimarisi geliştirilecektir.

3.1.1 Derin Öğrenmenin Tarihsel Özeti

Derin öğrenme, makinelerin sorunları tanımlamasına ve dünyayı bir ilkeler ağı olarak yorumlamasına olanak tanıyan bir tür makine öğrenmesidir (Kim, 2016). Derin öğrenme, yapay sinir ağları ile ortaya çıkmıştır (Deng ve Liu, 2018). Son on yılda, derin öğrenme birçok alandaki uygulamalarda önemli ilerleme kaydetmiştir (Liermann vd., 2019). Bilgisayar kendi kendine öğrendiği için bir insan bilgisayar kullanıcısının, bilgisayara gereken tüm bilgileri açıkça belirtmesine gerek yoktur. Makine analizi, gerçek verilerle başlayıp daha sonra karar vermeye yardımcı olmak üzere ilgili bilgileri çıkarılır (Wani vd., 2020). Derin öğrenme, bu görev için tasarlanan modellerle öznetelikleri otomatik olarak çıkarmaktır. Derin öğrenmenin temel avantajı, ilgili bilgileri elde ederek modelin genellenebilirliğini geliştirmesidir.


Bu bölümde derin öğrenmenin uzun geçmişini ayrıntıyla anlatmak yerine, gelecekte alacağı yön özetlenecektir. Goodfellow vd. (2016) derin öğrenme eğilimlerini şu şekilde özetlemiştir:

- Derin öğrenme oldukça uzun ve seçkin bir geçmişe sahiptir. Bununla birlikte, çeşitli felsefi fikirleri temsil eden birçok terimden etkilenmiştir ve etkisi zaman içinde artmış veya azalmıştır.
- Alınabilecek eğitimin boyutu genişledikçe, derin öğrenme daha verimli hale gelmektedir.
- Yazılım ve donanım dahil olmak üzere bilgisayar altyapısı derin öğrenmede büyük gelişmelere yol açtığından, derin öğrenme yöntemleri önemli ölçüde geliştirilebilir.


- Yıllar boyunca derin öğrenme, son derece karmaşık sorunların üstesinden yüksek çözünürlükle gelmiştir.

3.2 Evrişimsel Sinir Ağı Mimarisi

Evrişimsel sinir ağı, iki ve üç boyutlu görüntülerle çalışmak üzere tasarlanmış, ızgara benzeri bir mimariye sahip bir tür sinir ağıdır; ancak tek boyutlu girdi ile de kullanılabilir (Gasparin vd., 2022). Yapay sinir ağı çeşitli alanlarda geniş bir uygulama yelpazesi ile yüksek başarıya sahip olmuştur (Da Silva vd., 2017; Suzuki, 2013). Girdi nöronları gizli katman nöronlarına bağlıdır ve son gizli katmandaki nöronlar çıkış katman nöronlarına bağlanıncaya kadar aynı şekilde devam eder. Bu bağlantıların tümü, öğrenmeye izin verecek şekilde değiştirilebilen, ağırlık olarak bilinen bir değere sahiptir. Bir nöronun bir sonraki katmana kısmen bağlı olması, ancak bu katmandaki bir veya daha fazla nörona seçici olarak bağlanması düşünülebilir. Birçok YSA topolojisinde ağırlıklı bağlantılar bir katman ile sadece bir sonraki katman değil, aynı zamanda takip eden bir veya daha fazla nöron katmanı arasında görülür (Walczak, 2018). Derin sinir ağı, sinir ağlarının yapılarını kullanan otomatik bir öğrenme yöntemidir. Sinir ağı boyunca "derin" ifadesi, gizli katmanların sayısından kaynaklanmaktadır. Yukarıda görüldüğü gibi geleneksel sinir ağı tek katman kullanırken, derin sinir ağı (DNN) birden çok katman içerir. Şekil 3.1 ve Şekil 3.2, evrişimsel sinir ağının ana yapısını göstermektedir.



Şekil 3.1 Derin sinir ağlarının ana yapısı (Georgiou vd., 2020)




Şekil 3.2 İleri geçişli ileri beslemeli sinir ağı

Son yıllarda, görüntü tanıma ve sınıflandırma görevleri için çok verimli olan evrişimsel sinir ağları ve tekrarlayan sinir ağları dahil olmak üzere farklı sinir ağı türevleri oluşturulmuştur. ESA'lar şu an birçok uygulamada kullanılan, devrim niteliğinde ve çok yaygın modellerdir. Temel olarak, ESA'lar 3 farklı katmana ayrılır: evrişim katmanları, ortaklama katmanları ve tam bağlı katmanlar.

3.2.1 Evrişim Katmanı ve Öznitelik Çıkarımı

Görüntü işlemede evrişimsel sinir ağları kullanılır. Şekil 3.3 herhangi bir ESA modeli için giriş görüntüsünün derinliğini, genişliğini ve yüksekliğini göstermektedir. Görüntüdeki öznitelikleri tespit etmek için ağ, çok sayıda eğitilmiş filtre kullanarak giriş görüntüsü üzerinde seri evrişimler gerçekleştirir (Véstias, 2021). Evrişimsel katman, farklı seviyelerde filtreler veya matrisler kullanarak özniteliklerin çıkarılmasıdır (Hassaballah ve Awad, 2020). Öznitelik çıkarımı için çalışırken resimlerin fiziksel parametrelerini koruyan eğitilmiş filtre benzeri paylaşımlı ağırlıkların evrişimleri, ESA'lar tarafından görüntü tanımayı gerçekleştirmek için kullanılır (Jolly vd., 2018). Ardışık evrişimler, giderek daha karmaşık öznitelikleri bulmak için önceki evrişimde tanımlanan öznitelikleri analiz eder. Bu yöntem, öznitelik çevirisine duyarsız kalırken karmaşık özniteliklerin öğrenilmesine imkan sağlar. Öznitelik çıkarma katmanı, görüntü özniteliklerinin çıkarıldığı yer olması açısından en önemli katmandır. Evrişim, giriş görüntüsünün küçük karelerini kullanarak öznitelik temsillerini öğrenerek, pikseller arasındaki uzamsal ilişkiyi korur. Görüntü, bir dizi öğrenme nöronunu kullanılarak evrişimlenir. Böylece çıktı

görüntüsünde, öznitelik haritalarını girdi olarak sonraki evrişim katmanına doğru beslemeye devam eden bir öznitelik veya aktivasyon haritası oluşturulur. (Basha vd., 2020) Ham giriş verilerinden probleme özgü öznitelikleri öğrenme kapasiteleri nedeniyle, evrişimsel sinir ağları bilgisayarlı görü gibi alanlarda el işçiliği kullanılan özniteliklere olan ihtiyacı azaltmıştır.




Şekil 3.3 Girdi resminin derinliği, genişliği ve yüksekliği

3.2.2 Etkinleştirme Fonksiyonu

Doğrultulmuş doğrusal birim etkinleştirme fonksiyonu, ImageNet 2012 yarışmasında başarılı olmuş olan AlexNet'in önemli bir bileşenidir. y , bir ağ düğümünün çıktısı olmak üzere bu yöntem, $\max(0, y)$ değerini döndürür. Şekil 3.4, Doğrultulmuş Doğrusal Birimin (*Rectified Linear Unit* : ReLU), negatifı sıfıra indirirken girişin pozitif bileşenini koruduğunu göstermektedir. Bu çalışma, öncelikle yeni bir yaklaşımda olumsuz girdilerle başa çıkmak için ReLU'yu yeniden yapılandırmayı amaçlamaktadır (Jiang vd., 2018). Derin sinir ağlarının son dönemdeki başarısı büyük ölçüde ReLU'ya dayanmaktadır denklem 3.1'de gösterildiği gibi. Daha tipik olan hiperbolik tan ve sigmoid fonksiyonlarıyla karşılaştırıldığında, bu katmanın temel avantajları, çıktıya verdiği seyreklik ve kaybolan gradyan problemini en aza indirmesidir.


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



Şekil 3.4 ReLU etkinleştirme fonksiyonu (Tammima, 2019)

3.2.3 Ortaklama Katmanı


Ortaklama katmanları, öznitelik haritası boyunca özniteliklerin varlığını vurgulayarak, harita örnekleme işlevselliğini sağlar. Ortalama ortaklama ve maksimum ortaklama, sırasıyla bir özniteliğin ortalama varlığını ve bir özniteliğin en aktif varlığını tanımlayan iki ana ortaklama stratejisini temsil eder. Ortaklama katmanı, Şekil 3.5'de görüldüğü gibi aynı sayıda ortaklanmış öznitelik haritası kümesi oluşturmak için her öznitelik haritasında ayrı ayrı çalışır.



Şekil 3.5 Ortalama ortaklama ve maksimum ortaklama yapısı

3.2.4 Tam Bağlı Katman

Tam bağlı katmanlar, Evrişimli Sinir Ağlarının bilgisayarlı görüden görüntülerin tanınması ve sınıflandırılmasında oldukça etkili olduğu gösterilen önemli bir unsurdur. ESA yöntemi, evrişim ve ortaklamayı, resmi özniteliklere ayırmayı ve ayrı ayrı değerlendirmeyi içerir. Bu adımın eklenmesiyle nihai kararı sınıflandırıcıya bırakan tamamen birbirine bağlı bir sinir ağı yapısına oluşmuştur. Derin ESA'nın tam bağlı bileşeni, en uygun ağırlıkları seçmek için kendi geri yayılma yöntemini kullanır. Şekil 3.6'de gösterildiği gibi, ağırlıklar her nörona atanır ve en uygun etiket tercih edilir. Son olarak, her bir etiketteki nöronların "oy"unu kazanan, kategori seçimini belirler.




Şekil 3.6 Tam bağlı katman yapısı (Tammına, 2019)

3.2.5 Sınıflandırma Katmanı

Veriler, başlangıçta hangi gruba ait olduğuna karar vermek için sınıflandırılır (Kim, 2017). Tam bağlı katman önceki aşamalarda bir evrişim katmanından alınan öznitelikleri kullanarak her sınıfın puanını değerlendirir. Tam bağlı katmanlar, son katman öznitelik haritalarını sayısal değere sahip vektörler biçiminde alır. Soft-max sınıflandırma katmanı olarak, tam bağlı ileri beslemeli sinir katmanları uygulanır. Bir ağ modeline kaç seviyenin dahil edilmesi gerektiğine dair net bir yönerge bulunmamaktadır AlexNet (Krizhevsky vd., 2012), LeNet (LeCun vd., 1998) ve VGG Net (Simonyan ve Zisserman, 2014) gibi diğer yapılarda çoğunlukla iki ila dört katman

görülmüştür. Tam bağlı katmanlar hesaplama açısından maliyetli olduğundan, son yıllarda çeşitli yollar araştırılmıştır. Örneğin, global maksimum ortaklama katmanı ve ortalama ortaklama katmanı, bir ağdaki parametrelerin sayısını önemli ölçüde azaltabilir. Sınıf sayısı, önceki katmanın çıktı boyutu kullanılarak elde edilir. Şekil 3.7: Nihai sonuç olarak sınıflandırma çıktısı ile evrimsel sinir ağı bloğunu göstermektedir.



Şekil 3.7 Temel evrimsel sinir ağı bloğu

3.3 Yüz Tanıma ve Yoklama

Yüz tanıma, uzun süredir popüler bir çalışma alanı olmuştur ve üstesinden gelinmesi zor bir problemler içerdiğinden bilim adamlarınca ilgi görmektedir (Mishra vd., 2022). Bireylerin güvenli, doğru ve güvenilir bir şekilde tanımlanması gerekliliği ve yüz tanımanın sağlam, güvenli ve özgün olması eğitim, güvenlik ve diğer birçok alanlarda bu teknolojinin büyük ilgi görmesini sağlamıştır. Son yıllarda gelişme gösteren derin yüz tanıma, pratik modeller ve araştırmalar için ciddi destek gerektirmektedir (Wang vd., 2021). Son zamanlarda, uzaktan eğitime olan talep önemli ölçüde artmıştır. Bu artış, öğrenmenin önündeki izolasyon ve sosyal mesafe gibi zorunlu koşullardan doğan engellerden kaynaklanmaktadır. Uzaktan eğitimde yüz öznitelik çıkarımı, özellikle sınav aşamasında katılımcıların konumlarının değişmesini engellediği için yüz özgünlüğünü kontrol bakımından önemlidir. Bu çalışmada yüz tanıma ve yoklama için yeni bir mimari sunulmaktadır. Deneyler, geliştirilen yoklama modelinin neredeyse tüm yüzleri tanıyabildiğini ve karşılık gelen etiketleri kaydedebildiğini göstermiştir.

Uzaktan eğitim, öğrenme ve bilgi kültüründe küresel bir konu haline gelmiş ve birçok ülkede eğitimin verilme şeklini büyük ölçüde değiştiren COVID -19 pandemisi (Casacchia vd., 2021) koşullarında 2020'de itibariyle daha da önemli hale gelmiştir.

(Li vd., 2021; Nazarova vd., 2021). Geleneksel eğitim verme biçimi, İnternet tabanlı, bilgisayar odaklı çevrimiçi eğitime dönüşmüştür (Mu ve Guo, 2022). Platform olarak interneti ve öğretim cihazları olarak cep telefonlarını veya bilgisayarları kullanan e-öğrenme, dünyanın çeşitli yerlerinde ve farklı dönemlerde eğitim amaçlı bilgi alışverişini mümkün kılmaktadır. Geçtiğimiz yıllarda dijital öğrenme, bilgi teknolojisinin ve her türlü eğitimin uygulanmasını ve gelişmesini daha iyi desteklemiştir (Sun vd., 2022). Bilgi endüstrisinin gelişmesi ve genişlemesiyle birlikte, giderek artan sayıda ders için insan kaynakları ve geliştirme verimliliğini önemli ölçüde artıran e-öğrenme formatı tercih edilmektedir (Zhou, 2021). Öğretmenler, hem çevrimiçi hem de çevrimdışı ortamlarda oturumlar sırasında ders anlatırken diğer taraftan manuel olarak öğrenci katılımını takip etmekte zorlanmaktadır (Agarwal vd., 2021).

Sosyal mesafe ve güvenlik derecesi burada en önemli faktördür (Abdullaev, 2020; Abduraximovich, 2021). Uzaktan eğitim, öğretmen ve öğrencilerin fiziksel olarak aynı yerde bulunmadıkları öğrenme sürecini ifade etmek için kullanılan terimlerden biridir. Çevrimiçi öğrenme ve uzaktan öğrenme gibi aynı anlama gelen birçok farklı terim vardır. Uzaktan eğitimde, öğretmen ve öğrenci birbirleriyle etkileşim halindedir. Yakın görünmelerine rağmen fiziksel olarak uzaktırlar. Öğretme ve öğrenme süreci, çevrimiçi dersi tamamlayan video görüşmeleri yoluyla yapılır. Öğretmen ve öğrenci arasındaki iletişim, video konferans yoluyla ideal öğrenme şekli olan yüz yüze öğrenmeye yaklaşabilir.

3.3.1 SVM ve Softmax Mimarisi

Destek Vektör Makinesi ve Softmax, bilgisayarlı görüde yaygın olarak kullanılan iki doğrusal sınıflandırmadır (Qi vd., 2017; Pellegrini, 2015; Tang, 2013). Bu sınıflandırma teknikleri, özellikle derin öğrenme modellerinde daha sık kullanılmaktadır. Ayrıca, Destek Vektör Makinesi ve Softmax istatistik, konuşma tanıma, karakter tanımlama ve diğer alanlarda kullanılmış ve derin öğrenme sürecinde oldukça önemli yöntemlerdir.

3.3.2 SVM Değeri ve SVM Kaybı

Değer (Score) Fonksiyonu, giriş görüntüsünden fotoğraf değerine kadar bir model olarak düşünülebilir. Temel bir lineer dönüşüm Denklem 3.2'de gösterilmiştir.

$$f(x_i, w, b) = wx_i + b \quad (3.2)$$

x_i , verilen giriş pikseli, W , kaynak görüntülerden ve nihai kategori sayısından hesaplanabilen toplam harita ağırlığıdır ve b , sapma vektörüdür. Değeri hesaplamak temelde basit bir matris işlemidir. Giriş görüntüsüne atanan puan hiçbir zaman tam olarak doğru olmayacaktır. Bu noktada, başka bir fonksiyon, Kayıp (Loss) Fonksiyonu, birincil olarak sadece skor fonksiyonu tarafından sağlanan skordan sapmayı yansıtmalıdır. Çok Sınıflı Destek Vektörü Makine Kaybı (Çok Sınıflı SVM Kaybı), SVM'de uygulanır. Çok Sınıflı SVM Kaybının arkasındaki temel fikir, her zaman, tamamlanan doğru puanın yanlış puandan en az bir büyük olmasıyla, Skor Fonksiyonu tarafından elde edilen puanları hesaplamaktır. SVM'de tanımlanan kayıp fonksiyonu Denklem 3.3 olarak gösterilebilir.

$$L_i = \sum_{y \neq y_i} \max(0, w_j^T x_i - w_{y_i}^T x_i + \Delta) \quad (3.3)$$

w_j ağırlığın j satırını temsil ederken, y_i girdi görüntüsünün gerçek kategorisini gösterir. Bu formülde, giriş görüntüsünün nihai puanını maksimum değeri geçmesi gerekir. Buna Hinge Loss da denir.

3.3.3 Softmax Değeri ve Softmax Kaybı

Softmax fonksiyonu, K gerçek değerlerinin bir değişkenini, toplamı bire eşit olan K gerçek değerlerinin bir vektörüne dönüştürür. Softmax, pozitif, negatif, sıfır veya birden büyük olan giriş değerlerini 0 ile 1 arasındaki değerlere dönüştürerek, bunların olasılık olarak tanımlanmalarını sağlar. Softmax fonksiyonu Denklem 3.4'te gösterilmiştir.

$$f_j(z) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (3.4)$$

Softmax'ta Loss Fonksiyonu, Denklem 3.5'te gösterildiği gibi temel olarak Cross-entropy loss şeklinde kullanılır.


$$L_i = -\text{Log} \left(\frac{e^{f y_i}}{\sum_j e^{f_j}} \right) \quad (3.5)$$

SVM'deki Loss Fonksiyonunda daha önce bahsedildiği gibi, Softmax'taki Loss Fonksiyonunun da giriş görüntüsünün sonuçlarını çapraz olarak alması gerekir.

Softmax'taki Loss Fonksiyonu, bilgi teorisi perspektifinden de anlaşılabilir. Loss Fonksiyonu, Denklem 3.6'te gösterildiği gibi iki olasılığın entropisi olarak görülebilir. Loss Fonksiyonunun amacı, gerçek sınıflandırma sonucu ile tahmin edilen sınıflandırma sonucu arasındaki hatanın boyutunu ölçmek ve ardından bu değere göre optimize etmek ve değiştirmektir.

$$H(p, q) = -\sum_x p(x) \log q(x) \quad (3.6)$$

Şekil 3.8'te gösterildiği gibi, p gerçek sınıflandırma olasılığını ve q , tahmin edilen sınıflandırma olasılığını gösterirken, bu formül Softmax'taki loss fonksiyonunun bir cross-entropy loss şeklinde olduğunu da yansıtabilir.



Şekil 3.8 SVM ve Softmax çıktı sınıflandırma sonuçları (Li vd., 2016)

4. METOD ve MATERYAL

Bu bölümde, yöntemlerimizi test etmek için çeşitli yüz görüntü özellikleri ve boyutlarına sahip çeşitli veri kümeleri sunuyoruz. Yüz tanıma için yeni yüz görüntü tanımlayıcıları geliştirdik. Ardından derin öğrenme modeli olan "Yüz Tanıma için Detaylı Bir Ağ" temelli bir tasarım geliştirdik ve daha sonra yüz tanıma ve yoklama için yeni bir CNN modeli ve yaklaşım sunuyoruz.

4.1 Tezin Yöntemi

Yüz tanımanın pratik kullanımında performansını artırma gerekliliği, bu konuda yapılan araştırmaların sayısını artırmıştır. Son birkaç yılda, çeşitli yöntemler geliştirilmiş ve sunulmuştur (Uplaonkar ve Patil, 2022). Herhangi bir sistemin çalışma aşamaları, veri toplama, ön işleme, öznitelik çıkarma ve sınıflandırmayı içerir. Bu tezde ele alınan yöntemler, son zamanlarda yüz tanımada önemli bir performans sergileyen el işçiliği kullanılan yöntem ve yapay sinir ağları olarak bilinen mühendislik tekniğine dayanmaktadır. İnsanların biyolojik sinir ağı, ESA mimarisi kavramı için bir temel oluşturmuştur.

Öznitelik çıkarımına yönelik mühendislik yöntemleri, araştırmacılar tarafından yapılan çeşitli görevleri daha etkin bir şekilde yerine getirdiğinden zamanla yaygınlaşmaktadır. Bilgisayarlı görü sorunları için, bu tezde en son teknoloji olarak kabul edilen öznitelik tabanlı yöntemler geliştirilmiştir. Çeşitli özniteliklerin bir kombinasyonunu kullanarak geliştirilen öznitelik tabanlı yöntemlerin etkililiği bir karşılaştırma tekniği kullanılarak değerlendirilmiştir. Yüz tanıma tekniğimizin özel değil, genel olduğunu düşünüldüğünde en iyi yaklaşımın bu olduğu düşünülmektedir.

Deneyisel çalışma, destek vektör makinesi [DVM] ve derin öğrenme [DÖ] ile makine öğrenimi kullanılarak gerçekleştirilmiştir. DVM ve DÖ, çeşitli alanlarda yaygın olarak kullanılan yenilikçi iki modeldir. Makine öğrenimi, çoğu tanıma alanında tercih edilen bir teknik haline gelmiştir. Bu tekniklerden biri de destek vektör makinesidir (DVM). DVM, iki sınıfı ayırabilen hiper düzlemi bularak sınıflandırma gerçekleştiren, regresyon ve sınıflandırma problemlerini ele alan bir denetimli öğrenme

algoritmasıdır. Bu tezde, eğitim ve test olmak üzere iki kategoriye ayrılan veri tabanlarını sınıflandırma yapmak için eğitmek üzere DVM kullanılmıştır. DVM sınıflandırmasının ayrıntılı bir açıklaması 2. Bölümde daha ayrıntılı olarak verilmiştir. DVM, çok sınıflı sınıflandırma sorunları için hata düzeltme çıktı kodları (HDÇK), ikili sınıflandırma ve bir topluluk yöntemi kullanmaktadır. HDÇK'de kullanılan yöntem *bire-karşı-diğerleridir*. Doğru sonuçlar elde etmek için bu tezde *bire-karşı-diğerleri* (One Against All) kullanılmıştır.

Derin öğrenme, insan beyninin veri işlemesini taklit ederek karar verme yapıları oluşturan bir yapay zeka sistemidir. Derin sinirsel öğrenme ve derin sinir ağı da sinir ağı mimarisini kullanan otomatik bir öğrenme stratejisini ifade eden terimlerdir. "Derin" terimi, sinir ağı içindeki gizli katmanların sayısını ifade eder. Standart sinir ağları yalnızca bir katman içerirken, derin sinir ağları (DSA), çok sayıda katman içerir. Son yıllarda, özellikle örüntü tanıma ve sınıflandırma uygulamalarında verimli olan evrimsel sinir ağları (ESA) dahil olmak üzere çeşitli sinir ağı modifikasyonları geliştirilmiştir. ESA'lar evrim katmanları, ortaklama katmanları ve tam bağlı katmanlar olmak üzere üç ayrı katman halinde düzenlenmiştir.

Verileri sınıflandırmak için kullanılan özniteliklerden anında öğrenebilme kapasiteleri nedeniyle, evrimsel sinir ağları (ESA'lar) büyük ilgi görmüştür. Bu nedenle, bu çalışmada derin öğrenmenin belirsizliğini daha iyi anlamak için, yüz tanıma için dört evrim katmanına ve iki maksimum ortaklama katmanına dayanan bir model önerilmiştir. Bu çalışma, çeşitli deneyler ve veri tabanları kullanılarak yapılmıştır. Önerilen model, yüz tanıma problemleri için üst düzey öznitelikleri test etmek ve çıkarmak için kullanılabilir. Bu, derin öğrenmede kaydedilen büyük ilerleme ile daha derin modeller tasarlamak için çok önemli bir yöntemdir.

Derin öğrenmenin belirsizliğini daha iyi ele alabilmek için, düşük seviyeli öznitelik çıkarımı için daha derin bir model önerilmiştir. Bu, son makine öğrenme tekniklerinin artan derinlikten nasıl etkilendiğini kavramak için çok değerli ve farklı yüz tanıma problemleri için verimli bir modeldir. Yeni bir model tasarlarken daha derin katmanların daha iyi performansını gösterdiğine dair hiçbir kural ve kanıt olmadığından, yüz tanıma zorluklarında başarılı performans elde etmek için katman

sayısı açısından önerilen yöntem öne çıkmaktadır. Test derinliği artarken test performansının nasıl değiştiği değerlendirilebilmektedir. Genişliğin artması durumunda bunun çok önemli olduğu çeşitli veri tabanları üzerinde bir dizi testle gösterilmektedir.

Uzaktan eğitimde yüz kaydının kullanılması durumunda yüz tanımayı birleştirmenin birçok zorluğu vardır. Bu zorluklar, bu alanda yüz tanıma kullanmanın gerekliliklerini ele alan araştırmaların eksikliğinden kaynaklanmaktadır. Yüz Kaydı, uzak bir konumda ve farklı taraflarda bir, iki, üç veya daha fazla kişinin görüldüğü kontrolsüz bir durumda bulunan bir kişinin kimliğinin doğrulanması olarak kabul edilir. Bu bağlamda modelin genellenebilirliğini artırmak için çoğaltma ve dönüştürme gibi birçok yöntem kullanılmıştır. Bu nedenle, en iyi performansı elde etmek için birçok yöntemi birleştiren bir mimari önerilmiştir. Bu tezde belirlenen seçim adımlarına dayalı olarak sunulan yüzleri kaydederek yüz tanıma ve doğrulama zorluklarını aşmaya yönelik bir model önerilmiştir. Sınıflandırma zorluğunun ortadan kaldırmak için, derin ESA modelini etkili mühendislik öznitelik çıkarma yöntemleriyle birleştirme önerilmektedir. Yüz yoklama modeli, çeşitli gerçek mesafe uygulamalarının bir parçası olarak kullanılmak üzere geliştirilmiştir. Bu nedenle, başarılı yüz tanıma ve yoklama için en etkili durumu değerlendirmek için, önerilen model farklı veri tabanları üzerinde araştırılmıştır.

Her iki yöntem için de performansın değerlendirilmesi için en geçerli teknikler kullanılarak, insan performansını geride bıraktığı düşünülen ileri teknoloji tabanlı yöntemlerle bir karşılaştırma yapılmıştır. Bu tezin geçerliliğini sağlamak amacıyla yüz tanıma ve yoklama alanında son zamanlarda elde edilen sonuçlarla mevcut sonuçları karşılaştırmak için farklı veri tabanları üzerinde her yöntem için inceleme gerçekleştirilmiştir. Böylece, yüz tanımada performans karşılaştırması için yapılan deney ve incelemeler için önerilen tekniklerin geçerliliğini ve güvenilirliğini sağlamaya yönelik adım atılmıştır.

4.1.1 Yüz Tanıma Veri Tabanları

Yöntemleri test etmek için çok çeşitli yüz görüntüsü özelliklerine ve boyutlarına sahip birkaç veri tabanı seçilmiştir. Ele alınan spesifik problemten bağımsız olarak, tekniğin genellenebilirliğini kanıtlamak ve istikrarlı sonuçlar ve yüksek doğruluk sağlamak için çok çeşitli yüz görüntüsü türleri gerekmektedir. Yüz veritabanı geliştirme, yüz tanıma araştırmalarının ilerlediği yön üzerinde önemli bir etkiye sahiptir (Dalvi vd., 2022). Uzaktan eğitimde yüz tanıma ve yoklama için önerilen modelin uygulanması için veri tabanlarının seçimi bu çalışma için önemlidir. Sınıfta toplanan veri tabanı model doğrulaması için seçilmiştir. Bilgisayarlı Görü Bilimsel Araştırma Projesi (Computer Vision Science Research Projects), dört veri klasörü ortaya koymuştur (Faces94, Faces95, Faces96, Grimace) (Spacek, 2009). Yüz veritabanı, erkek ve kadın olmak üzere toplam 395 yüz içerir ve her katılımcı için 20 görüntü içerir. Çoğunlukla üniversite birinci sınıf öğrencileri olmak üzere farklı etnik kökenlerden insanların fotoğraflarını içerir. Katılımcıların çoğu 18 ila 20 yaş arasında olmakla birlikte daha ileri yaşta olan katılımcılar da vardır. Bazı kişiler gözlüklü ve sakallıdır. Face94'te 20'si kadın, 113'ü erkek, 20'si erkek olmak üzere 152 kişi olmak üzere toplam 3060 kişi yer almaktadır. Görüntülerin çözünürlüğü 180 x 200 pikseldir. Bir bireyin değişik özellikleri bazı öznitelikleri özetlemek için sunulmuştur.

Face95 veri tabanı 72 erkek ve kadın katılımcı içerir ve her katılımcı için 20 adet görüntü olmak üzere toplam 1440 görüntü vardır. Öznitelikler, kafayı çevirme ve bazı ifade varyasyonlarını içerir. Face96, 151 katılımcıdan toplanan toplam 3013 numuneyi içermektedir. Görüntülerin çözünürlüğü 196 x 196 pikseldir. Bu veritabanındaki öznitelikler, büyük ölçekli olarak kabul edilir ve bazı ifadeler yüz görüntülerinin bazı özelliklerini içerir. Grimace veritabanı, 18 erkek ve 20 kadına ait 180 x 200 piksel çözünürlüğe sahip görüntüler içerir. Veritabanı, ana ifade varyasyonlarını içerir. Ayrıca merkezi ışıklandırma, gözlüklü, mutlu, soldan ışıklandırma, gözlüksüz, normal, sağdan ışıklandırma, üzgün, uyuklu, şaşırılmış ve göz kırpmış gibi birçok özelliği içeren DVM algoritmasını değerlendirmek için Yale yüz veritabanı ve özel poz ışıklandırmaları için Genişletilmiş Yale B veritabanları kullanılmıştır. Çalışmanın deseni hakkında daha fazla ayrıntı 2. Bölümde verilmektedir.

4.1.2 Face94 Veri Tabanı

Face94, 20 kadın 113 erkek ve 20 erkek personel olmak üzere 152 katılımcıdan alınan toplam 3060 görüntüden oluşmaktadır. Görüntülerin çözünürlüğü 180 x 200 pikseldir. Bir bireyin varyasyonları, bazı öznitelikleri özetlemek için Tablo 4.1'de sunulmuştur ve Şekil 4.1, Faces94 yüz veri tabanından aynı bireyin bazı yüz örneklerini temsil etmektedir.

Tablo 4.1 Face94 veri tabanı özellikleri

Arka Plan	Başın Çevrilmesi	Yüz Pozisyonu	İfade Değişkenliği
Düz Yeşil	Çok az değişkenlik	Az değişkenlik	İfade Değişikliklerinin düşünülmesi



Şekil 4.1 Aynı bireye ait bazı örnekler

4.1.3 Face95 Veri Tabanı

Face95 veritabanı, 72 katılımcının her birine ait 20 görüntü olmak üzere toplam 1440 örnek görüntü içermektedir. Karakteristikler arasında, Tablo 4.2'de gösterilen özelliklerin yanı sıra başın çevrilmesi ve bazı yüz ifadesi varyasyonları yer alır. Şekil 4.2, aynı bireye ait görüntü grubunu göstermektedir.

Tablo 4.2 Bazı Face95 veri tabanı özellikleri

Arka Plan	Kafa Boyutu	Yüz Pozisyonu	Işıklandırma Değişkenliği
Kırmızı Perde	Büyük Boyutlu	Bazı Değişiklikler	Önemli Ölçüde



Şekil 4.2 Aynı insana ait farklı baş ve ışıklandırma durumları içeren görüntüler

4.1.4 Face96 Veri Tabanı

Face96, 151 katılımcının her birinden 20 adet olmak üzere 3013 adet görüntü içermektedir. Görüntülerin çözünürlüğü 196 x 196 pikseldir. Bu veri tabanının öznitelikleri büyük ölçekli olarak kabul edilir. Yüz görüntüsünün bazı özniteliklerini içeren ifadeler, Tablo 4.3'te yer almaktadır. Şekil 4.3, konum değişiklikleri içeren gerçek zamanlı görüntü yakalamayı göstermektedir.

Tablo 4.3 Face96 yüz veri tabanı özellikleri

Arka Plan	Yüz Pozisyonu	Işıklandırma Değişkenliği
Karmaşık	Bazı Değişiklikler	Önemli Ölçüde



Şekil 4.3 Face 96 veritabanından aynı bireye ait farklı yüz görüntüleri

4.1.5 Grimace Veri Tabanı

Veritabanı, her kişi için 180x200 piksel görüntü çözünürlüğüne sahip 18 görüntüden oluşmaktadır. Veritabanı önemli ifade varyasyonları içerir. Tablo 4.4'te bu ve diğer bazı özellikler gösterilmektedir. Şekil 4.4 aynı bireye ait farklı görüntüleri göstermektedir.

Tablo 4.4 Grimace yüz veri tabanının özellikleri

Arka Plan	Yüz Pozisyonu	Işıklandırma Değişkenliği
Sade	Bazı Değişiklikler	Çok Az




Şekil 4.4 Grimace veri tabanından aynı kişiye ait bazı yüz görüntüleri

Bu çalışmada dört veri setini kullanmanın amacı, karşılaştırma yapabilmektir. Bu da artan zorluk derecesine sahip veri tabanlarının (Faces94, Faces95, Faces96, Grimace) biyometrik işleme yoluyla yüz tanıma sonucu değerlendirmeleri ve karşılaştırmaları ile gerçekleştirilmektedir. Faces96 ve Grimace sözü geçen veri tabanı arasında farklı sebeplerden açık ara en zorlayıcılarıdır: Faces96 veri tabanı arka plan ve boyut bakımından çok fazla değişkenlik gösterirken; Grimace veri tabanında ifadelerde önemli ölçüde değişkenlik vardır. Yüz tanıma ve yoklama zorluklarıyla ilişkili oldukları ve diğer yöntemlerle karşılaştırmaya olanak sağladıkları için ulaşılabilen veri tabanları seçilmiştir. Diğer çalışmalarda bunlar genellikle modelleri doğrulamak ve performans değerlendirmeleri yapmak için kullanılmaktadır. Bu veri tabanlarının özellikleri büyük ölçekli olarak kabul edilir ve bunlar yapı ve özelliklerine göre dört gruba ayrılır. Bu özellik birçok avantajı beraberinde getirir ve araştırmanın farklı durumları test etmesini sağlar. Önerilen modeli uzaktan eğitimde yüz tanıma ve yoklama için kullanıldığından çalışma için veri seti seçimi gereklidir. Model doğrulama için sınıfta elde edilen veri tabanları seçilmiştir.

4.1.6 Yale Veri Tabanı

Yale Yüz Veritabanı, Yale projesine ait (Yale Yüz Veritabanı, n.d.) 15 katılımcının her birinden farklı koşullar altında elde edilen 11 resim ile toplam 165 siyah beyaz görüntüden oluşur. Loş aydınlatma koşulları, parlak aydınlatma koşulları, orta aydınlatma koşulları, gözlük kullanılarak değişen aydınlatma koşulları içermektedir. Şekil 4.5, Yale Yüz Veritabanından iki kişiyi göstermektedir.



Şekil 4.5 Yale yüz veri tabanından iki farklı kişiye ait yüz görüntüleri

4.1.7 Genişletilmiş Yale B Veri Tabanı

Genişletilmiş Yale B, her katılımcı için 9 poz ve 64 aydınlatma koşuluna sahip toplam 16128 yüz görüntüsü ve 28 sınıf içermektedir. Şekil 4.6, aynı kişiye ait bazı örnekleri göstermektedir.



Şekil 4.6 Genişletilmiş Yale B veritabanından aynı kişiye ait bazı örnekler.

Bu çalışmada yüz tanıma için yeni bir teknik geliştirilmiş ve bu model Yale yüz veri setlerinin farklı grupları üzerinde test edilmiştir. Bu tür veri tabanının önemli avantajlarından biri de güçlü aydınlatma değişkenlikleri içermesidir. Bu veri tabanlarının ana dezavantajı, görüntülerin siyah beyaz olmasıdır. Bu, bu tür bir görüntüye dayanan yöntemlerin kullanımını zorunlu kılacaktır.

4.1.8 Yüz Tanıma Veri Tabanları

Bu çalışmada uzaktan eğitimde yüz tanıma ve yoklama için önerilen modeli uygulamak için veri setinin seçimi büyük önem taşımaktadır. Sınıfta toplanan veri seti model doğrulaması için seçilmiştir. Tablo 4.5, bu belgede kullanılan dört veri tabanının genel özelliklerini göstermektedir. Deney, 5’li çapraz doğrulama kullanılarak değerlendirilmiştir. Ek işlem yapmadan dört veri tabanı, minör sol ve sağ döndürmeyle çoğaltılmıştır.

Tablo 4.5 Yüz tanıma veri tabanlarının özeti

Veri Tabanı	Katılımcı Sayısı	Görüntü Sayısı	Arka Plan	Kafa Çevirme	Kafa Boyutu	Yüzün Duruşu	İfade Değişiklikleri	Aydınlatma Değişiklikleri
Faces94	152	3060	Sade yeşil	Çok az değişiklik	yok	Küçük değişiklikler	Düşünülen ifade değişiklikleri	yok
Faces95	72	1440	Kırmızı perde	Çok az değişiklik	Büyük kafa boyut değişiklikleri	Bazı Değişiklikler	Bazı İfade Değişiklikleri	Belirgin Aydınlatma Değişiklikleri
Faces96	151	3013	Karmaşık	Çok az değişiklik	Büyük kafa boyut değişiklikleri	Bazı Değişiklikler	Bazı İfade Değişiklikleri	Belirgin Aydınlatma Değişiklikleri
Grimace	18	360	Sade	Önemli Değişiklikler	Küçük kafa boyut değişiklikleri	Bazı Değişiklikler	Büyük İfade Değişiklikleri	Çok Az

4.2 Yüz Tanımda Yeni Bir Öznitelik Çıkarım Modeli

Bu bölümün ana amacı, yüz tanıma için yeni öznitelik çıkarma teknikleri geliştirmektir. İlk olarak Yerel İkili Örüntü yönteminden türetilen Multi Descriptor adlı yeni modelle başlanmıştır. İkinci olarak, yüz yapısı ve görünümüne dayalı çift öznitelik tanımlayıcılarını kullanarak bir yüz tanıma modeli geliştirilmiştir. Üçüncü olarak, iki model arasındaki benzerlik ve farklılıkları araştırmak için yüz tanıma için çift yerel ikili örüntü adı verilen yeni bir model geliştirilmiştir. İki modelin nihai karşılaştırması ve değerlendirilmesi son teknoloji yöntemlerle yapılmaktadır. Her iki yeni model için de eğitim, kamera mesafesi, ifade, büyük kafa ölçeği ve ışık varyasyonu gibi yüz tanıma sorunlarının üstesinden gelmek için çeşitli yüz veritabanlarında destek vektör makinesi kullanılarak gerçekleştirilmiştir. Önerilen yöntem Genişletilmiş Yale B ve Grimace veritabanlarında sırasıyla %99,437 ve %100 mükemmel doğruluk elde etmiştir.

Yüz görüntüsü tanıma, örüntü tanıma araştırması alanında iyi bilinen bir terim olmasının yanı sıra çok önemli bir araştırma konusudur (Tang ve Shabaz, 2021). Teknoloji ilerlemeler yüz tanıma teknolojisini günümüz toplumunda son derece değerli hale getirmiştir (Liu vd., 2022) ve bilgisayarlı görüntülemenin en önemli parçalarından biri yüz tanımadır (Gavriell vd., 2021). Yüz tanıma, makine öğrenmesinin en önemli uygulama alanlarından biridir (Somogyi, 2021). Bilgisayarlı

görü alanında yüz tanıma konusu giderek daha fazla ilgi görmektedir (Shirindi vd., 2021). Yüz tanıma, bilgisayarlı görü ve görüntü işleme uzmanları arasında öne çıkan bir konudur (Kumar ve Hussaini, 2021). Yüz tanıma, en gelişmiş biyometrik tanımlama sistemleri arasındadır (Thomas, 2021). Bilgisayarlı görü ve örüntü tanımadaki yüz biyometri tanımlaması zor bir konudur (Shamrat vd., 2022). Geniş uygulama yelpazesi nedeniyle yüz tanıma, akademik ve endüstri alanlarında en çok araştırılan konulardan biridir (Abushanap vd., 2021; Biswas ve Blanco-Medina, 2021). Gerçek durumlardaki basitliği ve esnekliği nedeniyle yüz tanıma bilgisayarlı görü alanında büyük ilgi görmektedir (Abdullah ve Stephan, 2021; Yu vd., 2021; Zeng vd., 2021). Yüz tanıma, bilgisayarlı görü alanının en önemli ve zor çalışma konularından biridir. Bilgisayarlı görü ile karşılaştırıldığında, insan görme sistemi, bir hedefi karmaşık arka planlardan hızlı ve etkili bir şekilde ayırt edebilmektedir (Wang vd., 2021). Birincisi, bir dizi yüz fotoğrafının aynı kişiye ait olup olmadığını belirlemeye çalışırken, diğeri, bir dizi yüz görüntüsünden kişiyi tanımlamaya ve en yakın olanı bulmaya çalışır. Ancak gerçek dünya uygulamalarında yüz tanıma hala zor bir görevdir (Ben Fredj vd., 2021; Shamrat vd., 2021). Yüz tanıma sistemlerinin performansı mükemmel görünmektedir. Bununla birlikte, bir dizi parametreye bağlı olan yüz verilerinin kalitesi bu algoritmalar için kritik öneme sahiptir. Yüzün görüntüsündeki değişiklikler, aydınlatma, baş açısı ve görsel oklüzyonların yol açtığı değişikliklerden kaynaklanır (Méndez-Llanes vd., 2022). Yüz tanıma, genel kişisel kimlik ve güvenlik için gittikçe büyüyen bir sorun haline gelmektedir. Şu an kullanılan yüz tanıma sistemleri, yüzdeki pozisyon değişikliği, aydınlatma değişiklikleri ve oklüzyon sorunları gibi zorluklarla karşı karşıyadır (Bhangale vd., 2021). Yüz bir bireyi diğerinden ayırması itibarıyla en önemli biyolojik özelliktir. Birine kişisel olarak onay vermemiz gerektiğinde sadece yüzünü tanımlar ve doğrularız. Yüz tanıma, akıllı bir sistem/makinenin insan davranışını taklit etmesiyle gerçekleşir ve yüz tanıma, bir dizi fotoğraftan veya bir veri tabanından bir insan yüzünü tanımlama bilimidir. Çeşitli alanlarda birçok uygulaması olduğu için çok önemli bir çalışma konusudur (Gupta vd., 2021). Son yıllarda bireysel yüz tanıma, popüler bir araştırma konusu olmuştur. Olağanüstü etkililiği ve muazzam sosyal etkileri nedeniyle, son beş yıl içinde makine öğrenmesi, derin öğrenme ve akıllı sistemler gibi çeşitli disiplinlerden önemli ölçüde araştırmacının ilgisini çekmiştir (Ali vd., 2021). Çoğu yüz tanıma yöntemi fotoğraflar düşük ışıktaki çekildiğinde, loş yüz görüntülerinin özneliliklerinin normal aydınlatmalı

olan mevcut görüntülerin niteliklerine tam olarak uymamasından dolayı yetersiz çalışır. Sorun, yalnızca yüz fotoğraflarının aydınlatmasının iyileştirilmesi ve ardından elde edilen görüntüler üzerinde yüz tanıma işleminin gerçekleştirilmesiyle çözülemez (Huang ve Chen, 2022). Yüz tanıma görevleri genellikle yüksek kaliteli yüz fotoğraflarında gerçekleştirilir, ancak gerçek hayatta çekilen çoğu yüz fotoğrafı kontrolsüz ortamda veya kötü çekilmiştir (Li vd., 2022). Yüz tanımanın doğruluğu, görüntü kalitesi (Ma, 2021), değişken aydınlatma koşulları, kişinin konumu ve kameraya olan uzaklığı gibi problemlerden olumsuz yönde etkilenebilir (Badave ve Kuber, 2021).

Tanıma alanında, farklı özelliklere sahip çok sayıda yüz veri seti vardır ve yeni yöntemi değerlendirmek için uygun veri setlerini seçmek zordur. Bu çalışmada, neredeyse yüz tanıma sorunları ele alınmıştır. Algoritmaları değerlendirmek için altı veritabanı seçilerek çeşitlilik sağlanmıştır. Yale 165; Genişletilmiş Yale B 16300; Face94 3060 örnek içermekte; Face95, Face96 ve Grimace kullanılmıştır.

4.3 Karekök Denklemi

Ön işleme filtresinin tasarlanmasının temel amacı, yüz görüntüsü görünümünü, siyah beyaz geleneksel görünümünden, yeni bir görünüme dönüştürerek bu tür bir iyileştirmenin bulgulara nasıl bir farklılaşmaya yol açabileceğini göstermektir. Karekök denklemi (*Square root equation: SRE*) denklemi 4.1'de operatörünün ana fikri aşağıdaki gibidir: İlk adım, yüz görüntüsünü siyah beyaza dönüştürmektir. İkinci adım, bir (m-n) görüntüde 3-3 penceresinin merkez noktası olarak (xT, yT) piksel noktalarını almaktır. Üçüncü adım, komşu sekiz piksel değerleri a0-a7 olmak üzere merkez nokta piksel değeri (xT, yT) çevresine karekök uygulayarak gT değerini bulmaktır. Denklem 4.1'de gösterildiği gibi merkezi nokta piksel değeri ile değiştirilen son öznelik noktasının eklenmesiyle ve bitişik sekiz piksel değerlerinin kareleri toplamı olan 255 değerinden çıkarılmasıyla elde edilmektedir.

$$SRE = 255 - \sum_{s=0}^{Z-1} (\sqrt[2]{(adjacent(g_s) * \sqrt[2]{p})} \quad (4.1)$$

Burada $z = 8$, $p = 1, 2, \dots, N$: $N \leq 16$ ve merkez deęerinin üç komşusu iken, p deęeri 1'den 16'ya kadar olabilir, bu da çeşitli farklılaşmaları beraberinde getirir. Buna dayanarak, uyum her p deęeri kullanım amacına uygun olarak seçilmelidir. 4.6'deki algoritmalar, karekök denklemlerinin işlenmesi için tamamlanması gereken adımları içeren sözde kodu göstermektedir. Şekil 4.7'de, çıktının karekökünü hesaplama yöntemleri açıklanmaktadır. Her karekök sonucu uygun şekilde ayarlanmalı ve sonuç kaliteye baęlı olarak farklılık göstermelidir. (a) Eşsiz bir görsel; (b) üç komşuluk ölçümü; (c) orta noktanın üç komşusunun karekökü; ve (d) $P = 5$ olan denklem çıktısının sonucu. Karekök denklemi için sözde kod aşağıdaki gibidir:

Tablo 4.6 Karekök denklemi için sözde kod

1	START
2	INPUT face image
3	READ the value of P
4	FOR each pixel in input image
5	FOR each 3*3 neighbors
6	COMPUTE SRE new feature as
7	$SRE = 255 - \sum_{s=0}^{Z-1} (\sqrt[2]{\text{adjacent}(g_s)} * \sqrt[2]{p})$
8	Replace the new value SRE with center pixel of 3*3 with new image
9	ENDFOR
10	ENDFOR
11	SHOW the new face image
12	End


Karşılaştırma sonuçları aşağıdaki gibidir:

90	128	50	30	230	90	200
60	70	200	70	50	80	70
200	250	190	60	200	240	20
230	210	160	200	50	60	210
20	50	190	40	10	60	180
(a)						
90	128	50	30	230	90	200
60	70	200	70	50	80	70
200	250	190	60	200	240	20
230	210	160	200	50	60	210
20	50	190	40	10	60	180
(b)						
10	12	8	30	230	90	200
8	0	15	70	50	80	70
15	16	14	60	200	240	20
230	210	160	200	50	60	210
20	50	190	40	10	60	180
(c)						
90	128	50	30	230	90	200
60	36	200	70	50	80	70
200	250	190	60	200	240	20
230	210	160	200	50	60	210
20	5	190	40	10	60	180
(d)						

Şekil 4.7 Karekök hesaplama aşamaları

Şekil 4.7’de karekök sonucunu hesaplama aşamaları sunulmaktadır. Sonuç, değere bağlı olarak değişir ve her karekök değerinin yuvarlanması gerekir. (a) Orijinal bir resim gösterimi, (b) Üç komşunun ölçümü, (c) Orta noktanın üç komşusunun karekökü ve (d) $P=5$ iken formül çıkış değerini ifade eder.

Karekök tekniğinin sonuçları Şekil 4.8’de gösterilmiştir. Gri tonlama düzeyine uyum sağlamak için 1 ile 15 arasında herhangi bir değer kullanıldığında, farklı P değerleri yüz görüntüsünde farklılaşmalara neden olur. COVID-19 pandemisi için kullanılan bu yöntem hakkında daha fazla detay için (Salamh vd., 2021).



Şekil 4.8 Farklı P değerlerinin etkisi

4.4 Önerilen Yüz Tanıma Yöntemi

Görünüme dayalı öznitelik çıkarma, yüz detaylarının görüntüsüne odaklanır. Verimlilik, doğruluk ve dayanıklılık gibi birçok nedenden dolayı en önemli yöntemlerden biridir. Görünüme dayalı olarak önerilen öznitelik çıkarımının ana işlevi, merkez değerini eşik olarak kabul etmek ve bir öznitelik olarak yeni bir değer üretmek için sekiz komşu ile karşılaştırmaktır. Çoklu tanımlayıcı modellerin avantajı, bir yüz görüntüsünü tanımlayan değerleri belirleyerek ayırt edici özellikler sunmalarıdır. Önerilen yöntem, 0 ile 255 arası piksel yoğunluğu olan siyah beyaz bir görüntüde sekiz komşuyu merkez değeriyle karşılaştırarak, MD1 ve MD2 tarafından belirtilen farklı yöndeki iki yapıyla karşılaştırmak için oluşturulmuş denklemin tanıtılmasıyla başlamaktadır.

4.4.1 Teorinin Çıkarımının İspatı

İlk LBP yöntemi, her pikselin etrafındaki merkezi piksel değerini ikili olarak kodlamak için 3x3 komşu piksellerin merkezi pikselinin eşik değeri olarak kabul edilmesiyle çalışır. Merkezi piksel değeri g_p ve sekiz komşuluk g_c ile gösterilir (Topi vd., 2000). G_p 'den g_c 'nin çıkarılması sonucu elde edilen değer negatif veya pozitif olabilir. Denklem 1'de görüldüğü gibi, negatif değer 0 olarak, diğer değerler 1 olarak kodlanır. Son olarak, ikili kod özniteliği göstermek için ondalık bir değere dönüştürülür. Denklemin çıkarımı 4.2 ile başlamaktadır:

$$LBP = \sum_{p=0}^{p-1} f(g_p - g_c) 2^p \text{ where } p = 8 \quad (4.2)$$

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4.3)$$

Siyah beyaz görüntü için $2^8 = 256$ 0 ile 255 arasında olabilir ve denklem 4.2 255'e bölünür.

$$\frac{LBP}{255} = \frac{\sum_{p=0}^{p-1} f(g_p - g_c) 2^p}{2^8} \quad (4.4)$$

Böylece,

$$\frac{LBP}{255} = \sum_{p=0}^{p-1} f(g_p - g_c) 2^{(p-8)} \quad (4.5)$$

$\frac{LBP}{255}$ Denklemi bağı olarak, bu çoklu tanımlayıcı filtresi (MD) tarafından $p=0$ 'dan $p=8$ 'e kadar gösterilir.

$$MD = f(g_p - g_c) 2^{(0-8)} + f(g_p - g_c) 2^{(1-8)} + f(g_p - g_c) 2^{(2-8)} + f(g_p - g_c) 2^{(3-8)} + f(g_p - g_c) 2^{(4-8)} + f(g_p - g_c) 2^{(5-8)} + f(g_p - g_c) 2^{(6-8)} + f(g_p - g_c) 2^{(7-8)} \quad (4.6)$$

$$MD = f(g_p - g_c) 2^{(-8)} + f(g_p - g_c) 2^{(-7)} + f(g_p - g_c) 2^{(-6)} + f(g_p - g_c) 2^{(-5)} + f(g_p - g_c) 2^{(-4)} + f(g_p - g_c) 2^{(-3)} + f(g_p - g_c) 2^{(-2)} + f(g_p - g_c) 2^{(-1)} \quad (4.7)$$

Siyah beyaz görüntü $2^8 = 256$ olarak düşünülür, $0 \rightarrow 255$ olarak gösterilir.

Tablo 4.7 İkili değerin ondalık sayıya çevrimi

$2^{(-8)}$	$2^{(-7)}$	$2^{(-6)}$	$2^{(-5)}$	$2^{(-4)}$	$2^{(-3)}$	$2^{(-2)}$	$2^{(-1)}$
$\frac{1}{255}$	$\frac{1}{128}$	$\frac{1}{64}$	$\frac{1}{32}$	$\frac{1}{16}$	$\frac{1}{8}$	$\frac{1}{4}$	$\frac{1}{2}$
0,00393	0,0078	0,01563	0,03125	0,0625	0,125	0,25	0,5

Tablo 4.7'ye bakıldığında, Denklem 3.7 şöyle gösterilir:

$$MD = f(g_p - g_c) 0,00393 + f(g_p - g_c) 0,0078 + f(g_p - g_c) 0,01563 + f(g_p - g_c) 0,03125 + f(g_p - g_c) 0,0625 + f(g_p - g_c) 0,125 + f(g_p - g_c) 0,25 + f(g_p - g_c) 0,5 \quad (4.8)$$

Denklem 4.8 100 ile çarpıldığında,

$$MD * 100 = f(g_p - g_c) 0,393 + f(g_p - g_c) 0,78 + f(g_p - g_c) 1,563 + f(g_p - g_c) 3,125 + f(g_p - g_c) 6,25 + f(g_p - g_c) 12,5 + f(g_p - g_c) 25 + f(g_p - g_c) 50 \quad (4.9)$$

Her değeri en yakın aşağı veya yukarı değere yuvarlanarak toplam düzenlenir.

X değeri 100'e eşittir. $MD = (LBP)/255$.

$$\frac{LBP}{255} * 100 = f(g_p - g_c) 1 + f(g_p - g_c) 1 + f(g_p - g_c) 2 + f(g_p - g_c) 3 + f(g_p - g_c) 6 + f(g_p - g_c) 12 + f(g_p - g_c) 25 + f(g_p - g_c) 50 \quad (4.10)$$

Denklem 4.10 255 ile çarpılır ve 100'e bölünür.

$$MD = (f(g_p - g_c) 1 + f(g_p - g_c) 1 + f(g_p - g_c) 2 + f(g_p - g_c) 3 + f(g_p - g_c) 6 + f(g_p - g_c) 12 + f(g_p - g_c) 25 + f(g_p - g_c) 50) * \frac{255}{100} \quad (4.11)$$

$$MDN = (f(g_p - g_c) 1 + f(g_p - g_c) 1 + f(g_p - g_c) 2 + f(g_p - g_c) 3 + f(g_p - g_c) 6 + f(g_p - g_c) 12 + f(g_p - g_c) 25 + f(g_p - g_c) 50) * 2,55 \quad (4.12)$$

MD(N), N denklem 4.12'deki tanımlayıcı sayısını göstermektedir.

$$MDN = (f(g_p - g_c) 50 + f(g_p - g_c) 25 + f(g_p - g_c) 12 + f(g_p - g_c) 6 + f(g_p - g_c) 3 + f(g_p - g_c) 2 + f(g_p - g_c) 1 + f(g_p - g_c) 1) * 2,55 \quad (4.13)$$

0'dan 8'e kadar komşu sayısı olabilirken, X bir öznitelik değerini gösterir.

$$MDN = (f(g_p - g_c) x_8 + f(g_p - g_c) x_7 + f(g_p - g_c) x_6 + f(g_p - g_c) x_5 + f(g_p - g_c) x_4 + f(g_p - g_c) x_3 + f(g_p - g_c) x_2 + f(g_p - g_c) x_1 + x_0) * 2,55 \quad (4.14)$$

4.14 denklemden, her x, öznitelik olan yeni bir değeri ifade eder.

$$MDN = (x_8 f(g_p - g_c) + (\sum_{i=7}^{n=0} \frac{x_{(i+1)}}{k} f(g_p - g_c)) * 2,55 \quad (4.15)$$

Denklem 4.15'te 8'den 0'a X değerinin ($x_8, x_7, \dots, x_0$) yeni MD komşuları üretir ve 256 yerine 255 yazılarak denklem 4.16 kurulur:

$$MDN = x_8 + (\sum_{i=7}^{n=0} \frac{x_{(i+1)}}{k}) \quad (4.16)$$


$k = 1$ 'den n 'e kadar olmak üzere, burada n 100 veya 100'den küçük bir değer alabilir. Her X komşu değeri için merkez pikselle karşılaştırılır ve denklem 4.17'de gösterildiği gibi zıt bir değerle değiştirilir. Denklem 4.18 ve 4.19'da gösterildiği gibi, sekiz komşu için her x değeri merkez pikselle karşılaştırılır ve yeni karşıt değerle değiştirilir.

$$MDN = (x_8 f(g_p - g_c) + (\sum_{i=7}^{n=0} \frac{x_{(i+1)}}{k} f(g_p - g_c))) * 2,55 \quad (4.17)$$

$$F(x) = \begin{cases} X \geq 0 & \text{ise yeni değer} \\ \text{Değilse} & 0 \end{cases} \quad (4.18)$$


$$F(x) = \begin{cases} X \leq 0 & \text{ise yeni değer} \\ \text{Değilse} & 0 \end{cases} \quad (4.19)$$

Burada $p = 8$ iken ve hesaplama tamamlanana kadar 8'den 2'ye değiştirilebilir. İlk adım, sonraki algoritma adımlarını uygulayarak yukarıdaki denklemden x_8 ve x_0 değerlerini elde etmektir. X değerlerinin toplamı 100'e eşit olmalıdır. k değerinin X değerinden küçük olması ve birinci kuralın sağlanması gerekir. X değerlerinin son toplamı, öznitelik değerini gösterir. Kesir noktası 1. adımı karşılayacak şekilde yuvarlanır. Dağılımı sağlamak için X değerinin çeşitliliğine dikkat edilmelidir. x_8 ve x_0 değerleri uygulamaya göre değişmektedir. Optimal değer deneysel olarak seçilmiştir. Denklem 4.17'yi kullanmanın amacı, 1'den 8'e kadar herhangi bir sayıda sekiz komşu ile kullanılabilen ve sistemin davranışına dayalı olarak sadece bir komşunun kullanılmasına izin veren uygulamaya dayalı öznitelikler üretmektir. Şekil 4.9, çeşitli dağılımlara sahip farklı tanımlayıcı gruplarını göstermektedir.



Şekil 4.9 Tanımlayıcının farklı dağılımlara sahip çoklu yapıları

Öznitelik çıkarma yöntemlerinde farklı sayıda merkez piksel komşuları kullanmanın avantajları vardır. Şekil 4.10, farklı sayıda piksel kullanmanın yüz görüntüsü üzerindeki etkisini göstermektedir. Sonuçlar, merkez pikselden yüz özneliğini temsil etmek için seçilen pikselin konumuna dayalıdır. Ayrıca, iki veya daha fazlasının kullanılmasına izin verilmesi farklı sayıda yüz özneliğinin elde edilmesine yol açar. Sonuçlar yüz tanıma ve ilgili alanlarda büyük önem arz etmektedir.



Şekil 4.10 Yüz görüntüsünde farklı komşular kullanmanın etkisi

0 ile 255 arasında değişen piksel yoğunluğu değerlerini gösteren siyah beyaz bir görüntüde sekiz komşunun değerleri karşılaştırılmıştır. x değerleri aralığı verilerin eşit olarak dağıtılmasını sağlar, dolayısıyla kullanılan x_8 ve x_0 değerleri ihtiyaca bağlı olarak değişir. Şekil 4.11, Genişletilmiş Yale B veritabanının orijinal fotoğraflarına

(4.17)–(4.19) çok tanımlayıcı denklemlerin uygulanmasını göstermektedir. Şekil 4.12 ve Şekil 4.13 çıktıları göstermektedir.



Şekil 4.11 Genişletilmiş Yale B’den farklı ışıklandırma koşullarına ve aynı bireye ait bazı örnekler




Şekil 4.12 Genişletilmiş Yale B’den MD1 modeliyle üretilen örnekler




Şekil 4.13 Genişletilmiş Yale B'den MD2 modeliyle üretilen örnekler

MD, orijinal siyah beyaz görüntüden alınan özellikleri çıktı olarak verir. N , özniteliklerin boyutu olmak üzere, $1'e N$ özellikleri içeren bir vektör oluşturulur. Verilen öznitelikler, bir resmin seçili alanlarından bölgesel şekil verilerini temsil eder. Bu veriler, tanımlama, doğrulama ve görselleştirme gibi çeşitli amaçlar için kullanılabilir. Şekil 4.14, MD modeli ve LBP modeli için farklı öznitelik boyutlarını göstermektedir. Yüz görüntüsünü temsil eden vektör boyutluluğunun oluşturulmasında farklılıklar vardır. İki model aynı örnekle karşılaştırıldığında, MD modelinin LBP modelinden daha küçük bir vektör boyutu oluşturduğu açıktır, bu da MD modeli için bir başka avantaj olarak kabul edilir. Öznitelik gösterimi için daha az veri olduğundan dolayı boyutluluk farkı önemlidir. Birkaç örnek için öznitelik vektörü boyutluluğu Şekil 4.15'da gösterilmektedir. Son olarak, MD modeli tüm örnekler için farklı öznitelik vektörleri üretir.




Şekil 4.14 Öznitelik vektörü boyutluluğu a) MD modeli, b) LBP modeli



Şekil 4.15 Farklı örnekler için öznelilik vektörü boyutluluğu a) MD modeli, b) MD modeli.

4.4.2 Destek Vektör Makinesi

Makine öğrenmesi, başlıca alanlarda çok kullanılan bir yöntem haline gelmiştir. Yöntemlerden biri de destek vektör makinesidir (SVM). Destek Vektör Makineleri, Vapnik-Chervonenkis teorisine (Bhavsar ve Panchal, 2012) dayalı sağlam bir teorik altyapıya sahip son teknoloji bir algoritmadır. SVM fikri aslen sinir ağlarından türetilmiştir veya başka bir deyişle SVM, sinir ağlarının matematiksel bir gelişimidir. Hem doğrusal hem de doğrusal olmayan veriler SVM kullanılarak sınıflandırılabilir (Chandra ve Bedi, 2021). Regresyon ve sınıflandırma problemleri üzerinde çalışan bir denetimli öğrenme algoritması olan SVM, Şekil 4.16'da gösterildiği gibi iki sınıfı ayırabilen hiper-düzlemde arama yaparak sınıflandırma gerçekleştirir. Bu çalışmada, sınıflandırma gerçekleştirmek için eğitim ve test olmak üzere iki kategoriye ayrılan ilgili veritabanlarını eğitmek için SVM kullanılmıştır. Son bulgulara göre, destek vektör sistem sınıflandırıcıları, diğer sınıflandırma yaklaşımlarına kıyasla örüntü tanıma yüksek yüz tanıma performansı sergilemektedir. Bununla birlikte, destek vektör makinesi eğitim parametrelerinin seçimi destek vektör makinesinin etkinliği üzerinde önemli bir etkiye sahiptir (Nabat vd., 2022). Destek vektör makinelerini kullanan yüz tanıma yıllardır mevcuttur, ancak dengesiz veriler tarafından sınırlanmaktadır ve hesaplanması uzun zaman almaktadır (Jain ve Yadav, 2022). SVM, hata düzeltme çıktı kodları (HDÇK), ikili sınıflandırma problemi ve çok sınıflı sınıflandırma problemi topluluğu yöntemini kullanır. HDÇK'de kullanılan yöntemler bire karşı diğerleridir. Doğru sonuçlara ulaşmak için bu tezde bire karşı diğerleri yaklaşımı kullanılmıştır.




Şekil 4.16 İki boyutlu uzay, SVM ayrılması (Chandra ve Bedi, 2021; Mangasarian ve Musicant, 2001)

4.4.3 Çoklu Tanımlayıcı Öznitelik Çıkarımı Modeli


Önerilen algoritmanın amacı, yeni bir yüz öznitelik çıkarım yöntemi tasarlamak ve yüksek yüz tanıma doğruluğu elde etmektir. Bu, özellikle gerçek zamanlı sistemlerde 4,17; 4,18 ve 4,19 denklemlerine dayanan yüz tanıma problemlerini çözebilmek için gereklidir. Tanıma mimarisi iki bölüme ayrılmıştır:

Histogram eşitleme yapmak, yüz özniteliği çıkarımında ayarlanmış piksel yoğunluğunu kullanarak yüz görüntüsünün kontrastını artırmak için önemli bir adımdır. Bir görüntünün kontrastı, histogram eşitleme yöntemi uygulanarak iyileştirilebilir (Xiong vd., 2021). Görüntü işlemenin en zor yanı doğal ışığı korumaktır. Kontrast iyileştirme için en temel ve yaygın olarak kullanılan yöntemlerden biri histogram eşitlemedir (HE) (Dhal vd., 2021). Histogram eşitleme, bir görüntüdeki gri seviyelerin sayısını azaltarak bilgi kaybına ve tutarsız bir görünüme neden olur (Vijayalakshmi ve Nath, 2021). Şekil 4.17, önerilen modelin denklem (4.17)'e dayalı bir çift tanımlayıcıdan oluştuğunu göstermektedir. Son bölümde açıklanan sırasıyla (4.18) ve (4.19) denklemlerine dayalı olarak geliştirilen MD1 ve MD2 tanımlayıcıları birbirine entegre edilen farklı yöntem ve özniteliklere sahiptir. Bu, kullanılan sisteme bağlı olarak paralel olarak yürütülebilir. Bir sonraki adım, 3x3 olan histogram bloğunu hesaplamak ve her örnek için öznitelik vektörünü göstermektir. Son olarak, son öznitelik vektörünü oluşturmak için bir çift histogram

entegre edilmiştir. Önerilen model, öznitelik dağılımını sağlamak için iki farklı yöntemle öznitelik çıkarmaktadır. Modelin verimliliğini ölçmek için MDN ve çift LBP arasındaki performansı ortaya koymak amacıyla yöntemin aynı mimariyle oluşturulması sınırlılığı ile çift LBP modeli Şekil 4.18’de gösterilmektedir. Bu tezde kullanılan model 3x3 piksele sahiptir, ancak başka uygulamalarda 5x5 piksel üzerinde uygulanabilir.





Şekil 4.17 Çoklu tanımlayıcı model kullanılarak öznitelik çıkarımının mimarisi




Şekil 4.18 Çift yerel ikili örüntü kullanılarak öznitelik çıkarımı

Şekil 4.19, sınıflandırma için eğitim ve test setleri olarak adlandırılan iki ana bölümden oluşan çok tanımlayıcı bir model kullanan tüm mimariyi göstermektedir. Yüz yapısını göstermek için yüz öznitelikleri çıkarımı için aynı model uygulanmıştır. Birinci çoklu tanımlayıcı, ikinci çoklu tanımlayıcıdan farklı parametrelere sahiptir. Kurulan denklemin esnekliğine ve yüz özellikleri oluşturmaya yönelik açıklamalara dayanarak, MD1 x_8 için 50 ve x_0 için 0 değerini kullanırken, MD2 ise x_8 için 60 ve x_0 için 0 değerini kullanır. Bu tanımlayıcılar yüz görüntüsünün çeşitli örneklerini bir araya getirmektedir. MDN ve çift LBP modelleri arasındaki farkları göstermek zordur. Bu nedenle, Şekil 4.20'te yüz tanıma için yeni bir çift LBP mimarisi sunulmaktadır. Her iki model için sınıflandırma, sınıfları ayıran bir hiper-düzlem fikrine dayalı olarak tahmin yapmak için destek vektör makineleri kullanılarak gerçekleştirilir.



4.5 Verimli Bir Evrişimsel Sinir Ağı Mimarisi


Önerilen mimari, Tablo 4.8, Şekil 4.21 ve Şekil 4.22'da gösterilen VGG16 yapısına dayanmaktadır. İlk katman $224 \times 224 \times 3$ piksel görüntü boyutunda tutulmuş, filtre boyutun 4 *stride* ile 3×3 yerine 7×7 olarak değiştirilmiş ve 64 filtreli ikinci katmanı kaldırılmıştır. Bu, bir sonraki katmandaki vektörün boyutunu doğrudan azaltmakta ve ESA'nın bir dizi 64 filtre ile öznitelikleri öğrenmesini sağlamaktadır. Sonraki iki katman, 55×55 giriş boyutu ve 256 filtreli 3×3 filtre boyutu ile çalışır. Bunu, 3×3 boyutunda maksimum ortaklama ve *stride* 2 takip eder. Dördüncü evrişim, 27×27 giriş boyutunu ve 512 filtreli 3×3 filtre boyutunu, ardından 3×3 boyutunda maksimum ortaklamayı ve *stride* 2'yi kabul etmektedir. Son çıktı boyutu 6×6 'dır. Son olarak, son üç tam bağlı katman, VGG yüzünde olduğu gibi iki *dropout* ile 4096 nöronla tutulur. İşlemeyi hızlandırmak ve model kararlılığını sağlamak için, her *dropout* 0,5 ile test edilir ve her evrişim katmanı, yığın normalleştirme ve Düzleştirilmiş Doğrusal Birim (ReLU) tarafından takip edilir. Öğrenme oranı, ağı parametrelerinin kayıp gradyanına göre ne kadar ayarlandığını düzenleyen ayarlanabilir bir hiper-parametredir. Bu modelde en iyi sonucu veren e^{-03} ile e^{-04} arasındaki öğrenme oranı uygulanmıştır.



Şekil 4.21 Dört evrişimsel sinir ağı yapısı

Tablo 4.8 Yüz tanıma için önerilen evrimsel sinir ağı modeli

Katman Adı	Girdi Boyutu	Filtre Boyutu	# Filtre Sayısı	Ortaklama için Pencere Boyutu	Stride	Padding	Çıktı Boyutu	# Öznitelik Haritası
Conv1	224 × 224	7 × 7	64	-	4	0	55	64
Conv2	55*55	3*3	256	-	1	1	55	256
Conv3	55*55	3*3	256	-	1	1	55	256
Pooling1	55*55	-	-	3*3	2	0	27	256
Conv4	27*27	3*3	512	-	2	1	14	512
Pooling2	14*14	-	-	3*3	2	0	6	512
Fully Connected 1	4096-neurons							
Dropout	0,2							
Fully Connected 1	4096-neurons							
Dropout	0,2							
Fully Connected 3	N classes							
Softmax								



Şekil 4.22 Önerilen modelin gösterimi


4.6 Yüz Tanıma İçin Önerilen Derin Öğrenme Modeli

Önerilen mimari, 224X224x3 piksel boyutunda giriş görüntüsüne ve 7X7 filtre boyutlu bir ilk katmana sahiptir. Şekil 4.24 ve Tablo 4.9; 2 stride'lı Indepthnet mimarisinin, ESA'nın toplam 64 filtre ile daha ilgili öznelilikleri öğrenmesine izin verdiğini göstermektedir. Sonraki katman, 112'lik bir veri boyutuna ve 5X5'lik bir filtre boyutlu 64 adet filtreye sahiptir. Ağın ana bileşeni olarak önerilen normal blok, Şekil 4.23'da gösterildiği gibi bloğun nihai çıktısını tamamlamak için erken katmanın ortalama ortaklamasını içeren bir öğrenme mimarisine sahiptir. Denklem 4.20 ve 4.21, maksimum ve ortalama ortaklamaların kullanımının ana yapısını gösterir.


$$y = \max (F(x, \{W_i\})) + (x) \quad (4.20)$$

$$y = \max(F(x, \{W_i\})) + \text{avg}(x) \quad (4.21)$$

Çekirdek ağ, genişletilmiş blok için hem ortalama hem de maksimum ortaklama ile bloğun nihai çıktısını tamamlamak için ortalama ortaklamaların erken katmandan önce geldiği bir öğrenme mimarisine sahiptir. Tüm modellerde modelin işlenmesini ve kararlılığını (Ioffe ve Szegedy, 2015; Santurkar vd., 2018) hızlandırmak için her bir evrişim katmanını, batch normalizasyonu ve Düzleştirilmiş Doğrusal Birim (ReLU) takip eder. Son olarak, global ortalama ortaklama, tam bağlı katman ve softmax katmanı eklenir. Modeli eğitmek için Cross Entropy kayıp fonksiyonu uygulanır. Ağırlık güncellemeleri ve Kayıp fonksiyonunu optimize etmek için Momentumlu Stokastik Dereceli Alçalma (Buduma vd., 2022) uygulanır. Öğrenme hızı, sinir ağlarını eğitmek için kullanılan özelleştirilebilen bir hiper parametredir. Genellikle 0,0 ile 1,0 arasında küçük bir pozitif değere sahiptir. Modelin öğrenme oranı, zorluklara ne kadar hızlı uyum sağladığını gösterir. Bu model için öğrenme oranı, en iyi sonuçları elde eden e^{-04} değeridir.



Şekil 4.23 Inception v1 öğrenme yapısı, a) ağıın ana bileşeni olarak önerilen normal blok, b) bloğa dayalı daha derin ağı için genişletilmiş



Şekil 4.24 Ağ için normal blok ve Inception v1 yapılandırma bloku

Blok için temel katman olarak kullanılan ilk conv2d katmanını dışında, aynı blok kimliğine sahip maksimum ortaklama ve ortalama ortaklama ile down sample kullanılmıştır.

Tablo 4.9 Inception v1 mimarisi

Katman	Evrişim Sayısı	Çekirdek Boyutu	Kanallar	Stride	Girdi Boyutu
Input Image					224x224
Conv1	1	7x7	64	2	224x224
Conv1_1	1	5x5	64	1	112x112
Block 1	2	3x3	64	1	112x112
Block 2	3	3x3	128	1	55x55

Tablo 4.9'un devamı

Katman	Evrişim Sayısı	Çekirdek Boyutu	Kanallar	Stride	Girdi Boyutu
Block 3	3	3x3	256	1	27x27
Block 4	3	3x3	512	1	13x13
Block 5	3	3x3	1024	1	6x6
Block 6	3	3x3	2048	1	6x6

4.7 Uzaktan Eğitim Veri Setleri

Tüm yüzler doğrudan algılama ile elde edilmektedir. 2. Bölümde anlatıldığı gibi, çevrimiçi sınıftaki her yüz görüntüsü, yüz algılama yöntemi kullanılarak otomatik olarak kırpılmıştır. Algılama ve kırpma, her yüz için tek bir görüntüye dayanmaktadır. Ek olarak, çalışmadaki veri dönüştürmenin temel amacı, birkaç yüz görüntüsüne sahip sınıfların yanı sıra daha fazla yüz görüntüsüne sahip sınıfları işlemektir. Eğitim süreci tüm sistemlerin zorlayıcı ve önemli bir adımıdır. Bu yöntem, yüz öznitelik çıkarımı için önerilen ESA ve destek vektör makinesi kullanılarak uygulanır. Ayrıca, destek vektör makinesi ile sınıflandırıcı korunmaktadır. Bu önemli adım, sınıfları ayıran en iyi hiper düzlemi kullanan SVM'nin, sınıfları tanımlamak için softmax olasılık fonksiyonundan daha az hata eğiliminde olduğunu ortaya çıkarmıştır. Test aşaması, ekranda görünen yüzler üzerinde uzaktan yüz tanımaya dayanmaktadır.

4.7.1 Veri Çoğaltma

Eğitim veri setindeki orijinal görüntü ile aynı sınıfta olan resim varyasyonlarını işlemek için en iyi bilinen veri çoğaltma ve temel geliştirme yöntemi görüntü çoğaltmadır (Anusha ve Kiruthika, 2022). Büyük miktarda veri bulunmasına rağmen, model öğrenme farklı veri dağılımları nedeniyle önemli yanlılıklara eğilimlidir (Luo vd., 2021). Tek örnekle yüz tanıma yöntemi, tanımlama işlemini gerçekleştirmek için yalnızca bir örneğin kullanılmasına dayanmaktadır (Daniel, 2021). Tek örnekle yüz tanıma ile ilgili sorun, duruş, ifade ve aydınlatma farklılıklarını ayırt etmek için yeterli sayıda örnek olmamasıdır (Lee, 2021). Tek seferde öğrenme bunun bir örneğidir ve eğitim için sadece bir adet görüntü kullanılarak doğru bir tahmin yapılması gerekir (Rana ve Kisku, 2021). Güçlü bir hafızaya sahip bir kişi, çeşitli durumlarda bir yüzü


ayırt edebilse de, üzerinde çalışılacak çok az veri olduğunda bir makinenin bunu başarması zordur.

Sınırlı görsel özellikler ve yüz tanımlama ayrıntıları arasındaki kavramsal boşluk nedeniyle kişi başına tek örnek sorunu, yüz tanıma alanında her zaman önemli bir engel teşkil etmiştir (Liu vd., 2021). Çeşitli pozisyonlar ve aydınlatma koşulları üzerinde bir yüz kimliğinin önemli farklılıklarına sahip bir eğitim seti elde etmek son derece maliyetli olduğundan sınıf-içi yüz görüntülerinin çeşitliliğinin artırılması önemli bir sorundur (Shao vb., 2020). Bir test yüzü, modelin zayıf bir eğitim setinden öğrenmediği bilgileri içeriyorsa, yüz tanıma algoritması başarısız olabilir.

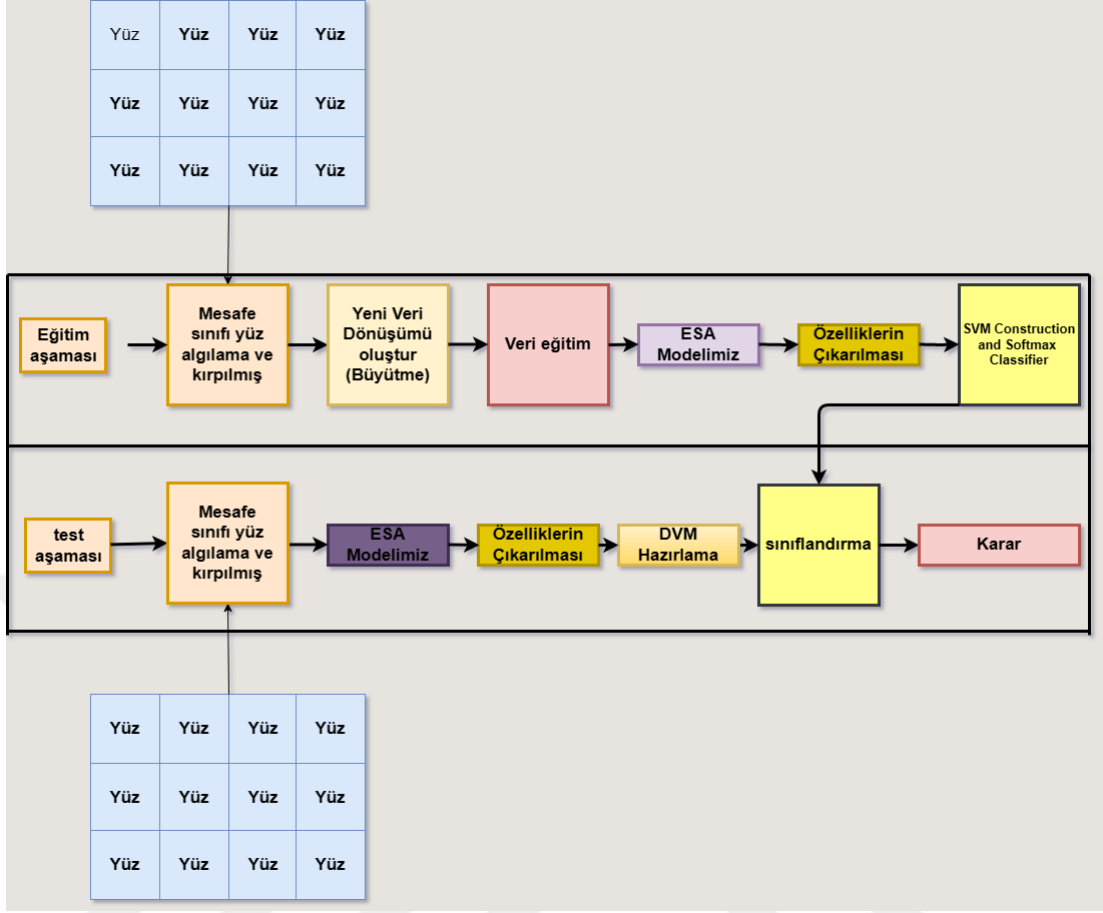
Tek seferde yüz tanıma, yeni kimliklerin yalnızca bir yüz fotoğrafından tanınması gereken zorlu bir görevdir. Yeterli eğitim örneği olmadığı için tek seferlik sınıflar doğrudan yok sayılabilir (Khong vd., 2021).

Genellikle "yüz verisi çoğaltma" olarak adlandırılan veri çoğaltma, yüz veri tabanı eksikliğini gidermek için yararlı bir yöntemdir. Bu yöntem, gerçek veya sanal yüz görüntülerini değiştirerek eğitim veya test setlerinin miktarını artırmaya yönelik bir yöntemdir (Dalvi vd., 2022). Veri çoğaltma parlaklık, kontrast ve doygunlukta veri değişiklikleri uygulayarak yüz tanımanın doğruluğunu artırmak için faydalı bir yöntemdir (Uchoa vd., 2020). Farklı çekim koşulları, tanınmayı zorlaştırabilecek beklenmedik fotoğraf kontrastlarına yol açar. Bu tür varyasyonlar, HSV dönüşümü kullanılarak kontrast bilgisinin dijital olarak değiştirilmesiyle elde edilebilir. Bu, orijinal yüz görüntü bilgisi korunurken, kontrastı %20 oranında artırıp azaltarak yeni kontrast bilgilerinin üretilmesi gerektiğini göstermektedir. Parlaklık ve aydınlatma varyasyonları, gerçek zamanlı bir işlem için zorlayıcı olmaya devam etmektedir. Temelde böyle bir eylemi algılamak için görüntünün parlaklığını değiştiren dönüşümler uygulanmıştır. Mevcut çalışmalarda, orijinal yüz görüntüsü tüm işlemlerde kullanılmaya devam ederken, parlaklık %20 oranında artırıp azaltılarak farklı bir koşula sahip yeni bir görüntü geliştirilmektedir. Zayıf aydınlatma koşulları ve kamera merceği dahil verimlilik, fotoğraf doygunluğunun aşırı yüksek veya aşırı düşük olmasına neden olabilir. Yüksek bir doygunluk değeri yüz görüntüsünde istenmeyen renklere yol açtığından doygunluk oranları HSV renk uzayının S-kanalı

kullanılarak oluşturulmuştur. Bunu yapmak için, doygunluk %20 oranında artırılıp azaltılmaktadır. Şekil 4.25, bu tezde uzay dönüşümü ve farklı sağ ve sol döndürmeler kullanılarak yapılan veri çoğaltmayı göstermektedir. Görüntüler, veri dönüştürme ve çoğaltma kullanılarak hazırlanmıştır. Bu yöntem, çevrimiçi yüz tanıma veri tabanlarını geliştirmek için kullanılır. Ayrıca, Şekil 4.26'te görüldüğü gibi sınıflandırıcının nasıl eğitileceği ile ilgili adımlar açıklanmaktadır.



Şekil 4.25 Uzay dönüşümü ve döndürme yöntemleri kullanılarak yüz tanıma için çoğaltmanın uygulanması



Şekil 4.26 Önerilen ESA ve DVM eğitim ve test mimarisi

4.7.2 Yüz Tanıma ve Uzaktan Yoklama Modeli

Fotoğraflar, gerçek dünya senaryolarında aynı veri tabanından rastgele seçilmez. Çünkü bu yöntemler tanıma sisteminin uygulanması sırasında veya sisteme yeni bir birey eklendiğinde eğitilmektedir. Tahmin için kullanılan görseller her iki tarafta da farklı zamanlarda sisteme gönderilir (Ediz, 2021).

Yüz tanıma modeli seçilmiş, doğrulanmış ve bu modelin neredeyse tüm zorlukların üstesinden gelebildiği kanıtlanmıştır. Çevrimiçi yüz tanıma ve yoklama modeli için, öznetelik çıkarımı için cosine benzerlik (*similarity*) yöntemi ve çoklu tanımlayıcılar kullanarak kaydı tamamlamak da görevin diğer bir aşamasını oluşturmaktadır (Lahitani vd., 2016; Nguyen ve Bai, 2011). Çoklu tanımlayıcılar, denklem 4.22, 4.23 ve 4.24'de görüldüğü gibi yüz doğrulaması için iki vektör oluşturmada kullanılır. Cosine benzerliği, denklem 3.31 kullanılarak hesaplanır. Test edilen görüntü ve tanımlanan görüntü olmak üzere iki görüntü M ve N ile gösterilir. Bu alanda kullanılan

en iyi algoritmalarından biri olduğu için cosine benzerlik algoritması sistem geliştiricileri ve veri analistleri tarafından çeşitli alanlarda yaygın olarak kullanılmaktadır. Bu algoritmanın en önemli özelliklerinden biri, veri boyutundan bağımsız olarak en iyi sonuçların alınmasında başardığı hız ve yüksek verimliliğidir. İki görüntü, öznitelik vektörleri olarak tanıtılmalıdır. 4.25 denkleminin değeri -1 ile 1 arasında değişirken, 1 tam benzerliği ve -1 tam farklılığı ifade eder. Denklem 4.27 ve 4.28’de Destek vektör makinesi ve softmax olasılık çıktısı için, eşik değeri makul bir değer olarak ayarlanmalıdır.

$$MD = (x_8 f(g_p - g_c) + (\sum_{i=7}^{n=0} \frac{x_{(i+1)}}{k} f(g_p - g_c))) * 2,55 \quad (4.22)$$

$$F(x) = \{X \geq 0 \text{ ise yeni değer,} \quad \text{Değilse } 0. \quad (4.23)$$

$$F(x) = \{X \leq 0 \text{ ise yeni değer,} \quad \text{Değilse } 0. \quad (4.24)$$

$$similarity(M, N) = \frac{M.N}{\|M\| * \|N\|} \quad (4.25)$$

İki görüntü M ve N ise, test edilen ve değerlendirilen yüz

$$similarity(M, N) = \frac{\sum_{i=1}^n M_i * N_i}{\sqrt{\sum_{i=1}^n M_i^2} * \sqrt{\sum_{i=1}^n N_i^2}} \quad (4.26)$$

$$s_1 = similarity(M_1, N_1) \quad (4.27)$$


$$s_2 = similarity(M_1, N_2) \quad (4.28)$$

Cosine benzerlik s_1 ve s_2 değerleri ve destek vektör makinesi çıktısı M_1 ve N_1 and M_1 ve N_2 ise softmax çıktısını gösterir.

$$Predicted(T) = \max(s_1, s_2) \quad (4.29)$$

T Denklem 4.29’te olduğu gibi başarıyla doğrulanan yüze yönelik son tahmindir.

Şekil 4.27'te görüldüğü gibi bu model, ESA, Softmax ve SVM'nin gerçek dünya uygulamalarındaki performansını ölçmek ve uzaktan eğitimde nasıl kullanılabileceğini netleştirmek için geliştirilmiştir. Denklem 4.29'te gösterildiği gibi, benzerliği daha iyi olan sınıf gerçek sınıf olarak kabul edilmelidir. Sistem, yüz sayısı referans alınarak yüzlerin tanınması ve kırılmasına göre ilerlemektedir. Yoklama işlemi sırasında herhangi bir hata oluşursa sistem referans numarasını kendisi değiştirir.



Şekil 4.27 Çevrimiçi yüz yoklama sisteminin bütün mimarisi

4.8 Yüz Tanıma Performansının Değerlendirilmesi

Makine öğrenmesi yöntemlerini kullanarak yüz tanıma modellerinin performansını hesaplamak ve değerlendirmek için, bu tezde en sık kullanılan matrisler şu şekilde tanımlanmıştır: Tüm matrisler için P pozitif ve N negatif örneklerin sayısını, T (*true*) doğruyu ve F (*false*) yanlış ifade etmektedir.

1. Doğruluk (accuracy: Acc), sınıflandırma performansını ölçmek için sıklıkla kullanılan göstergelerden biridir.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.30)$$

2. Hatırlama (Recall)veya Doğru Pozitif Oranı / True Positive Rate (TPR) Pozitif olarak sınıflandırılan örneklerin toplam örnek sayısını pozitif olarak yansıtır, aynı zamanda gerçek pozitif örnekler olarak da bilinir.

$$Recall = \frac{TP}{TP+FN} \quad (4.31)$$

3. Kesinlik (precision), doğru olarak sınıflandırılan pozitif örneklerin, tahmin edilen pozitif örneklerin toplam sayısına oranını gösterir.

$$Precision = \frac{TP}{FP+TP} \quad (4.32)$$

4. F-değeri veya F1 puanı kesinlik ve hatırlamanın harmonik ortalamasını yansıtır. F- değeri 0-1 arasındadır ve yüksek F-değerleri yüksek sınıflandırma performansını gösterir.

$$F1_score = \frac{2TP}{2TP+FP+FN} \quad (4.34)$$

5. Ortalama doğruluk, μ , aşağıdaki formülle elde edilir:

$$\mu = \frac{\sum_{i=1}^5 p_i}{5} \quad (4.35)$$

p_i geçerli sınıflandırma oranını göstermektedir.

6. İşlem Karakteristiği (ROC)

İşlem karakteristiği (Receiver operating characterictic: ROC) y eksenini TPR'yi ve x eksenini FPR'yi gösteren iki boyutlu bir grafikdir. ROC eğrisini oluşturmak için güven puanı eşiği değiştirilir. Her eşik sadece bir nokta üretir.

7. ROC Eğrisi Altındaki Alan (AUC)

AUC, ROC eğrisinin altındaki alan kullanılarak hesaplanır. Puan her zaman 0 ile 1 arasında sınırlıdır ve hiçbir mevcut sınıflandırıcının AUC'si 0,5'in altında değildir.

ROC eğrisinde farklı sınıflandırıcıları karşılaştırmak önemsiz değildir. Bunun nedeni, beklenen performansı gösteren sayısal bir değerin olmamasıdır.




5. BULGULAR ve YORUM

Bu bölümde araştırmanın bulguları çalışmanın yapısına göre ayrı ayrı sunulmuş ve yorumlanmıştır.


5.1 Çoklu Tanımlayıcı Modeli İle İlgili Bulgular

5.1.1 Yale Veri Tabanı Üzerinde Performans Değerlendirme

Şekil 5.1'de gösterildiği gibi, modelin tüm performansı %95,181 doğrulukla oldukça iyidir. Hatırlama ve kesinlik sırasıyla %95,152 ve %95,65'dir. Yanlış sınıflandırma oranı %4,8193 olarak verilmiş ve diğer matrisler tanıtılmıştır. Modelin katılımcı başına 15 olmak üzere 165 yüz görüntüsü etkilediği ve sonuçların oldukça iyi olduğu açıktır. Şekil 5.2, toplam %93,373 doğruluk, %93,33 hatırlama ve %93,558 kesinlik oranına ulaşan çift yerel ikili örüntülerin değerlendirme matrislerini göstermektedir. Yale veri tabanının zorluğu göz önüne alındığında LBP çiftinin nihai değerlendirmesi iyidir.




Şekil 5.1 Çoklu tanımlayıcı modelin Yale veritabanındaki yüz tanıma performansı




Şekil 5.2 Çift yerel ikili örüntünün Yale veritabanındaki yüz tanıma performansı

5.1.2 Genişletilmiş Yale B Üzerinde Performans Değerlendirme


Genişletilmiş Yale B 28 sınıf, 9 poz ve 64 aydınlatma koşuluna sahip toplam 16128 yüz görüntüsünden oluşmaktadır. Şekil 5.3'de görüldüğü gibi doğruluk, hatırlama ve kesinlik sırasıyla %99,437; %99,385 ve %99,387 olarak gerçekleşmiştir. F1 ile gösterilen harmonik ortalama %99,383'tür. Sonuçlara göre, belirli pozlar ve aydınlatma varyasyonu durumlarında modelin değerlendirilmesi mükemmeldir. Şekil 5.5, LBP model çiftinin %98,732 doğruluk oranı olduğunu göstermektedir. Hatırlama ve kesinlik %98,266 ve %98,246'dır. Diğer matrisler göz önüne alındığında, LBP model çifti anlamlı sonuçlar vermiştir. Çoklu tanımlayıcı ise farklı pozlar ve aydınlatmalar açısından daha iyi performans gösterir.



Şekil 5.3 Çoklu tanımlayıcı modelin Genişletilmiş Yale B veritabanındaki yüz tanıma performansı




Şekil 5.4 Genişletilmiş Yale B için Aydınlatma değişikliklerindeki performansı gösteren ROC eğrisi




Şekil 5.5 Çift yerel ikili örüntünün Genişletilmiş Yale B veritabanındaki yüz tanıma performansı

5.1.3 Face94 Veritabanı Üzerinde Performans Değerlendirme

Şekil 5.6'da, F1 değeri %98,817, hatırlama %98,814, kesinlik %98,662 ve hata oranı 1,1858 olmuştur. Diğer matrislere dayalı olarak, model, Şekil 5.6'de gösterildiği gibi, kafanın çevrilmesi, yüz konumu ve kameradan sabit bir mesafe ile ifade değişimi durumlarında %98,814'lük mükemmel bir doğruluğa ulaşmaktadır. Şekil 5.7, %98,715 doğrulukla LBP model çiftinin değerlendirmesini göstermektedir. Hatırlama ve kesinlik sırasıyla %98,684 ve %98,65'dir. Diğer matrisler göz önüne alındığında, LBP modeli önemli sonuçlar vermiştir. Çoklu tanımlayıcı ile karşılaştırıldığında, çift yerel ikili örüntünün toplam doğrulukta çok az farkla daha iyi performans sunduğu görülmüştür.



Şekil 5.6 Çoklu tanımlayıcı modelin Face 94 veritabanındaki yüz tanıma performansı




Şekil 5.7 Çift yerel ikili örüntünün Face 94 veritabanındaki yüz tanıma performansı


5.1.4 Face95 Veritabanı Üzerinde Performans Değerlendirme

Modelin F1 değeri %98,935'dir. Hatırlama ve kesinlik performansı sırasıyla %98,93 ve %99,03 olup ve toplam doğruluk %98,936'dır. Sabit kamera ve görüntü yakalanırken ileri bir adım atma ve yüz veritabanının getirdiği diğer zorluklara rağmen model, Şekil 5.8'de görüldüğü gibi %98,949'luk önemli bir doğruluk oranına ulaşmıştır. Şekil 5.9, yüz tanıma için toplam %99,439 doğrulukla çift yerel ikili örüntü modelinin performansını gösterir ve diğer matrisler son derece yüksekti. Face95 veri tabanına göre, hem çoklu tanımlayıcı hem de LBP model çifti önemli doğruluk

oranlarına ulaşırken, yüksek doğruluk üreten LBP çiftinin avantajlı olduğu görülmektedir.



Şekil 5.8 Çoklu tanımlayıcı modelin Face 95 veritabanındaki yüz tanıma performansı




Şekil 5.9 Çift yerel ikili örüntünün Face 95 veritabanındaki yüz tanıma performansı


5.1.5 Face96 Veritabanı Üzerinde Performans Değerlendirme

Face96, arka planda ve boyutlandırmada ve özellikle yüz ifadelerinde çok büyük olan değişiklikler nedeniyle oldukça zorlayıcıdır. Sonuçların değerlendirildiği matrisler Şekil 5.10'te gösterilmiştir. Elde edilen doğruluk %98,585 ve yanlış sınıflandırma oranı %1,4151'dir. Veritabanının özellikleri düşünülecek olursa modelin performansı kusursuza yakındır.

Şekil 5.11, %99,225 kesinlik ve %99,214 doğruluk ile çift yerel ikili örüntü modelinin yüz tanıma performansını gösterirken, diğer matrisler de oldukça yüksektir. Face96 veritabanının zorluğu dikkate alındığında, hem çoklu tanımlayıcı hem de LBP model çifti, yüksek doğruluk düzeylerine ulaşmıştır.



Şekil 5.10 Çoklu tanımlayıcı modelin Face 96 veritabanındaki yüz tanıma performansı




Şekil 5.11 Çift yerel ikili örüntünün Face 96 veritabanındaki yüz tanıma performansı


5.1.6 Grimace Veritabanı Üzerinde Performans Değerlendirme

Şekil 5.12 ve Şekil 5.13'de görüldüğü gibi, iki model de 0 hata oranıyla %100'lük kusursuz bir doğruluk elde etmiştir. Hatırlama, kesinlik ve F1 değeri optimaldir ve

Grimace veri tabanında, özellikle katılımcının görüntü alınırken hareket etmesi gibi zorluklara rağmen mükemmel sonuçlar elde edilmiştir. Karşılaşılan zorluklar düşünüldüğünde en iyi performans gösterilmiştir.



Şekil 5.12 Çoklu tanımlayıcı modelin Grimace veritabanındaki yüz tanıma performansı



Şekil 5.13 Çift yerel ikili örüntünün Grimace veritabanındaki yüz tanıma performansı

5.1.7 MD Modellerinin Performans Değerlendirmesi ve Karşılaştırması


Şekil 5.12, analizin özetini göstermektedir. Değerlendirme matrisleri, toplam pozitif örnek sayısı içindeki pozitif örneklerin yüzdesinin aynı zamanda gerçek pozitif örnekler olarak adlandırıldığını göstermektedir. Kesinlik, doğru olarak sınıflandırılan pozitif örneklerin toplam pozitif tahmin edilen örnek sayısına oranını gösterir. F1

değeri, kesinlik ve hatırlamanın harmonik ortalamasını yansıtır. F değeri 0 ve 1 arasında olabilirken, yüksek F değerleri yüksek sınıflandırma performansını gösterir. Tüm matrisler hem LBP çifti hem de MD tahminlerinin kusursuza yakın performansını göstermektedir.

Şekil 5.14, çoklu tanımlayıcı modelin Yale ve Genişletilmiş Yale B'deki ayrıntılı karşılaştırmasını göstermektedir. MD'nin en düşük tanıma doğruluğu %4,8193'lük bir yanlış sınıflandırma oranıyla %95,181'lik ulaşmıştır. Genişletilmiş Yale B'de ise %99,437 gibi yüksek bir doğruluk elde etmiştir. LBP çifti, en düşük tanıma doğruluğu performansı olan %93,33'e %6,6265 yanlış sınıflandırma oranıyla Yale veri tabanında ulaşmıştır. Genişletilmiş Yale B'de ise %98,73 doğruluk oranı vardır. MD modeli, LBP model çiftine kıyasla daha az ve farklı öznitelik vektörleri üretmiştir. Bu nedenle, iki modelin doğruluk seviyeleri farklıdır. Yale ve Genişletilmiş Yale B için ortalama MD doğruluğu %97,309 iken, LBP model çifti için %96,05'tir. Grimace, %100 ile en yüksek doğruluk oranına sahiptir. En düşük doğruluk, Face94 veri tabanına ait olan %98,814'dir. Grimace, LBP model çifti için %100'lük en yüksek doğruluğu sağlamıştır. En düşük doğruluk performansı ise, Face94 veri tabanına ait olan %98,71'dir. Yüz tanıma sorunları için 6 farklı veri tabanının içerdiği zorluklara dayanarak, her iki modelin de doğruluk oranı son derece yüksektir. Önerilen yüz tanıma yönteminde farklılıkları ortaya çıkarmak ve yüksek doğruluk oranı elde etmek için çoklu tanımlayıcı ve çift LBP kullanılmıştır. Şekil 5.15, MD ve LBP modellerinin %100'lük kusursuz performansını gösterir. LBP model çiftinde, Genişletilmiş Yale B için sırasıyla %99,437; %98,732 ve %97,55 gibi yüksek doğruluk elde edilmiştir. MDN modeli ve LBP çifti, Yale veri tabanında katılımcı başına örnek sayısının düşük olması nedeniyle oldukça makul olan %95,18 ve %93,37 doğruluk elde etmiştir. %98,81 doğruluğa sahip MD modeli, %98,71'lik doğruluk oranıyla LBP'den daha iyi performans göstermiştir. LBP model çifti ise Face95 ve Face96'da mükemmel bir doğruluk oranı elde ederek MD modelinden daha iyi performans göstermiştir.



Şekil 5.14 Farklı özelliklere sahip farklı veri tabanlarına ait hatırlama, kesinlik ve F1 değerlerinin özeti



Şekil 5.15 Yeni yüz tanıma modellerinin performanslarının karşılaştırması

Yale üzerinde yapılan deneyde yöntemlerimiz en modern yöntemlerle karşılaştırmalı olarak verilmektedir. Tablo 5.1'de, LBP ve MD modellerini kullanan iki yöntem, iyi bir doğruluk oranına ulaşmış ve diğer yöntemlerden daha iyi performans göstermiştir. MD modeli en iyi ortalama doğruluğu sağlamıştır.

Tablo 5.1 Yale yüz veri tabanı üzerinde modern yöntemlerin tanıma oranları

Yöntem	Doğruluk %
CSDL-SRC-power norm (Liu vd., 2016)	84,56
CSDL-CRC-power norm (Liu vd., 2016)	83,56
TSLDA (Chen vd., 2018)	84,77
Geliştirilmiş TSLDA (Chen vd., 2018)	87,89
MPLBP-LH (Reddy vd., 2015)	80,28
LBPHL (Reddy vd., 2015)	80,83

Tablo 5.1'in devamı

Yöntem	Doğruluk %
LBP- PCA (Truong ve Kim, 2018)	89,2
1D-LBP (Truong ve Kim, 2018)	91,50
EL-LBP (Truong ve Kim, 2018)	95,07
CLTP_S/M/C (Yee vd., 2020)	83,13
LapCLTP_S/M/C (Yee vd., 2020)	85,13
ART + SVM (Bensenane ve Keche, 2016)	89,4
SGD-LCDRC (Akheel vd., 2021)	90,07
LBP (Najafi Khanbebin ve Mehrdad, 2021)	83,4
DR-LBP (Najafi Khanbebin ve Mehrdad, 2021)	94,09
Bu Çalışmadaki LBP	93,73
Bu Çalışmadaki MD	95,18

Face94 ile yapılan denemede, bu çalışmada geliştirilen yöntemler en gelişmiş yaklaşımlarla karşılaştırılmaktadır. Tablo 5.2'te, LBP çifti ve MD modeli kullanan tüm yöntemlerin doğru ve önceki yöntemlerden üstün olduğu kanıtlanmıştır. MD modeli en yüksek düzeyde doğruluğa sahip olan modeldir.

Tablo 5.2 Face94 veritabanı üzerinde modern yöntemlerin tanıma oranları

Yöntem	Doğruluk %
SURF-detektör-SIFT-tanımlayıcı (Vinay vd., 2015)	87,76
SIFT + SURF (Gupta vd., 2021)	87,3
ART + SVM (Bensenane ve Keche, 2016)	96
DR-LBP + LDA+ SVM (Najafi Khanbebin ve Mehrdad, 2021)	96,4
DR-LBP + LDA + KNN (Najafi Khanbebin ve Mehrdad, 2021)	98,11
Bu Çalışmadaki LBP	98,71
Bu Çalışmadaki MD	98,81

Tablo 5.3'te görüldüğü gibi, Genişletilmiş Yale B üzerindeki denemede geliştirilen yöntemler en son tekniklerle karşılaştırmalı olarak gösterilmektedir, LBP çifti ve MD modeli kullanan her iki yöntemin de doğruluğu ve mevcut yaklaşımlardan üstün olduğu gösterilmiştir. MD modeli en yüksek doğruluk oranına sahiptir.

Tablo 5.3 Genişletilmiş Yale B yüz veri tabanı üzerinde modern yöntemlerin tanıma oranları

Yöntem	Doğruluk %
CSDL-SRC-power norm (Liu vd., 2016)	98,28
CSDL-CRC-power norm (Liu vd., 2016)	97,74
IPCA_SVM (Zhu vd., 2018)	89,30
DCNN (Zeng vd., 2018)	88,3
SGD-LCDRC (Akheel vd., 2021)	98,83
CNN-LBP-HOG (Yallamandaiah ve Purnachand, 2022)	97,33
Joint feature in a unified (Wan vd., 2021)	97,55
Bu Çalışmadaki LBP	98,73
Bu Çalışmadaki MD	99,43


Sonuçlar, yeni bir öznitelik çıkarım denklemi kullanan yeni tanımlayıcının farklı pozlar, aydınlatmalar, yüz ifadeleri ve gözlük kullanımı gibi durumlar üzerinde daha verimli olduğunu ve LBP modelinden daha iyi performans gösterdiğini ortaya koymaktadır. Bu, yeni modelin tanımlama, doğrulama ve tanımlama için öznitelik çıkarımını kullanan yüz tanıma ve diğer görevlerdeki zorluklar üzerinde çalışmaya uygun olduğu anlamına gelmektedir. Tanımlayıcı, ilk bölümde birkaç yüz görüntüsü üzerinde test edilmiş ve doğrulanmış; ve böylece yüz ayrıntılarını ne kadar iyi tanımlayabileceğini açıkça göstermiştir. Bu çok önemlidir ve yüzün tüm özniteliklerini ortaya koyabilme yeteneğini gösterir. Yeni tanımlayıcı ayrıca gelecekte çalışmayı planladığımız COVID-19, retina damarları ve doku sınıflandırması gibi diğer alanlardaki tanıma görevlerine katkı sağlayabilir.

Bu bölümde, yüz tanımada öznitelik çıkarımı için yeni kurulmuş bir denklem ile çok tanımlayıcılı bir model ve yeni bir LBP model çifti olarak kabul edilen iki ana katkı tanıtılmıştır. Sınıflandırma, bir destek vektör makinesi tarafından gerçekleştirilmiştir. Temel amaç yüz özniteliklerini bir dizi yöntem ve çeşitli dağılımlarla tanımlamak için türetilmiş denklemleri kullanmaktır. Bu yöntem yüz görüntüsü özniteliklerinin çıkarılması için tasarlanmıştır, ancak daha fazla tanımlayıcı içeren diğer birçok nesne tanıma türü için de kullanılabilir. MDN modeli, Genişletilmiş Yale B, Face94 ve Grimace veritabanları için sırasıyla %99,437; %98,814 ve %100'lük son derece önemli performanslarla LBP modeliyle karşılaştırıldığında önemli bir tanıma doğruluğu elde etmiştir; bu da önerilen yöntemin orijinal LBP'den tamamen farklı olduğunu ve pozlar, aydınlatmalar, ifadeler, yüz konumu ve kamera mesafesindeki değişikliklerin getirdiği


problemleri etkili bir şekilde çözerek yüz tanıma doğruluğunu geliştirdiğini göstermektedir. Veritabanlarında yapılan denemelerde, MDN ve LBP model çiftinin kesin, kararlı ve doğru olduğu görülmektedir. Gelecekteki çalışmalarda farklı veri dağılımlarına sahip farklı MD modelleri kullanılmalıdır.

5.2 Verimli Bir Evrimsel Sinir Ağı ile ilgili Bulgular

Aşırı (*overfitting*) ve yetersiz (*underfitting*) uyumun teşhisi, yüz tanıma için çok önemli bir adımdır. Şekil 5.16, Face94, Face95, Face96 ve Grimace için eğri doğruluğunu ve kaybını göstermektedir. Eğrilerin analizi, tüm veri tabanları için aşırı uyum meydana gelmediğini ve iyi uyum yakalandığını açıkça göstermektedir. Şekil 5.17, bir sınıflandırma modelinin değerlendirmesinin tüm veri tabanları için ideal olduğunu gösteren işlem karakteristik eğrisini (ROC eğrisi) göstermektedir. Gerçek pozitif orana (TPR) karşı yanlış pozitif oranın (FPR) çizilmesi, ROC eğrisini (FPR) vermektedir.




Şekil 5.16 Veri setleri için eğitim ve doğrulama doğruluk eğrileri




Şekil 5.17 Veri setleri için ROC eğrileri ve AUC

5.3 Derin Öğrenme Modeli ile ilgili Bulguları


Genel veri seti, diğer yaklaşımlarla karşılaştırmayı kolaylaştırdığı ve yüz tanıma ve sınıf kaydı sorunlarıyla ilgili olduğu için seçilmiştir. Diğer araştırmacılar tarafından da yaygın olarak kullanılmaktadır. Sonuçlar 5li çapraz doğrulama ile değerlendirilmiştir. Önerilen modellerin teşhisi, yüz tanıma için çok önemli bir adımdır. Şekil 5.18, veri tabanları için eğitim doğruluğunu, doğrulama doğruluğunu, eğitim kaybını ve doğrulama kaybını göstermektedir. Eğrilerin analizinden, tüm veri setlerinin iyi bir uyuma sahip olduğu görülebilir. Test edilen veri tabanları için, hatırlama, kesinlik ve F1 değeri kullanılarak yapılan performans karşılaştırması, Şekil 5.19'de gösterildiği gibi anlamlı sonuçlar vermektedir. Bu yöntemin yüz tanıma oranı, diğer son teknoloji derin öğrenme modelleriyle karşılaştırılmıştır. Şekil 5.20, test edilen veri tabanları için ideal performansı yansıtan AUC'nin 1'e eşit olduğu ROC eğrisini gösterir. Şekil 5.21, bu çalışmada geliştirilen modelin Face94 ve Grimace veri setleri için %100 doğrulukla diğer yöntemlerden daha iyi performans gösterdiğini ve Face95 için %99,86'ya ulaştığını göstermektedir. Face96 veri tabanı için ise model, resnet50 vedendennet201 ile karşılaştırıldığında 99,54'lük iyi bir doğruluğa ulaşmaktadır.




Şekil 5.18 Indepthnet19 için çeşitli veri tabanlarındaki eğitim ve doğrulama doğruluğu, eğitim kaybı ve doğrulama kaybı(a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace



Şekil 5.19 Farklı veri tabanlarında Indepthnet19'e ait performans karşılaştırması, (a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace



Şekil 5.20 Indepthnet ROC eğrisi, (a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace



Şekil 5.21 Indepthnet Karşılaştırması, (a) Faces94, (b) Faces95, (c) Faces96, (d) Grimace

Sonuçları açmak için, Farklı zorluklara sahip dört veri seti oluşturulmuştur. Geliştirilen model, veri tabanlarının sahip olduğu küçük kafa boyutu, yüz duruşu,

kafanın çevrilmesi ve büyük ifade farklılıkları gibi zorluklara karşın Face94 ve Grimace veri tabanlarında başarılı sonuçlar elde etmiştir. Önemli aydınlatma değişiklikleri ve büyük kafa boyutu farklılıkları olan Face95 için model, diğer yöntemlere göre çok daha iyi performans göstermiştir. Face96 veri tabanı büyük kafa boyutu farklılıklarına ve karmaşık bir arka plana sahip olduğundan diğer modeller gibi geliştirilen modelin de performansını hafifçe etkilemiştir. Indepthnet19'u daha iyi kullanmak için Face94, Grimace ve Face95'teki zorluklarda daha iyi performans göstereceği düşünülmektedir. Facenet için, Face96 veri tabanındaki doğruluk optimal değildir; bunun nedeni büyük olasılıkla bu veri tabanında farklı yüzler içeren çok sayıda yüz etiketi bulunmasıdır. Ancak, [26] tarafından belirtilen FaceNet sonuçlarının doğruluğu sadece %77,67'dir. Her yüz etiketinin birden fazla farklılığı olduğundan ve FaceNet eğitim yöntemi üçlü kaybı kullandığından bu oldukça makul görünmektedir.

Tablo 5.4'te görüldüğü gibi son yöntemlerin tümü, önemli performans elde etmektedir. Sonuçlar genel olarak Indepthnet19'un en etkili yöntem olduğunu ve diğer yöntemlerden daha iyi performans gösterdiğini, bunun da onu dört veri tabanının sahip olduğu zorluklar için daha ilginç hale getirdiğini ortaya koymaktadır.

Tablo 5.4 Bu çalışmada geliştirilen yöntemin diğer son yöntemlerle karşılaştırması

Yöntemler	Tanıma Oranı			
	Faces94	Faces95	Faces96	Grimace
XNORNET (Bharadwaj vd., 2019)	-	70,83	94,03	-
TT-3D (Brandoni ve Simoncini, 2020)	-	87,15	100	-
FaceNet_HOG_SVM (Wu ve Zhou, 2003)	-	83,90	97,94	-
KPCR (Pan vd., 2020)	-	98,2	95	-
FrMEM (Hosny vd., 2021)	100,00	92	99	100,00
Openface_ Random Forest (Khokhar vd., 2021)	98	96	93	98
Openface_ Ada Boost (Khokhar vd., 2021)	96	93	97	94
Inception-V3_ RandomForest (Khokhar vd., 2021)	91	89	93	81
Inception-V3_ Ada Boost (Khokhar vd., 2021)	96	95	97	94
Deeplearning_PSO (Khokhar vd., 2021)	99	99	97	98
fuzzy_FADF_ResNet-164 (Seethalakshmi ve Valli, 2022)	98,05	94,56	95,23	99,26
Bu Çalışmadaki Indepthnet	100	99,86	99,54	100

Derin öğrenme, öznetelikleri çıkarmak için karmaşık bir yol gerektirmeyen, yüz tanıma için etkili bir teknolojidir. Her katmandaki nöron sayısını gösterecek şekilde daha fazla katman kullanıldığında, derin öğrenme zorlaşır ve daha fazla işlem kaynağı gerektirir. Kaynaklar daha az katman kullanılarak azaltılsa da, evrimsel sinir ağı parametrelerinin ayarlanması gerekmektedir. Önerilen ESA, farklı veri boyutta veri tabanları kullanırken daha az kaynakla iyi bir performans sergilemektedir.

Bu bölümde, çeşitli ağ tasarım yöntemlerinden etkilenen yüksek performanslı bir yüz tanıma modeline sahip özel bir derin ağ olan Indepthnet tanıtılmıştır. Yaygın yüz tanıma kriterlerini kullanan denemelere göre, bu çalışmada geliştirilen Indepthnet doğruluk açısından başarılıdır. Model, mevcut kapsamlı derin yüz tanıma ağlarının çoğunluğu gibi her iki test kriterinde de iyi performans göstermektedir. Yüz tanıma için renk alanı değişikliklerine dayalı çoğaltma yönteminin bu alanda oldukça etkili olduğu görülmüştür. Bu çalışma herhangi bir sınıflandırılmış probleme uygulanabilir. Farklı amaçlar için farklı veri tabanları kullanılarak değerlendirilebilir.

5.4 Yüz Tanıma ve Uzaktan Yoklama Modeli ile ilgili Bulgular

Performans karşılaştırmaları temelde iki deney ile yapılmıştır. İlk deney, tüm sınıfların yüzlerinin tanınmasıyla ilgilidir. Şekil 5.22; Deney 1'de önemli sonuçlar gösteren SVM desteği ile önerilen ESA Softmax'ın, ön yüz ile farklı yüz ifadeleri ve hafif sağ ve sol dönüşlerde %100 doğruluk oranı ile çarpıcı sonuçlara ulaştığını gösterir. Bunun nedeni, tanımlama sürecini vurgulamak için kullanılan cosine benzerlik fonksiyonudur. Şekil 5.24, deney 2'de, büyük yüz ifadesi değişiklikleri ve geniş açılı sağ ve sola dönüşlerin yanı sıra farklı arka planlar ve büyük kafa boyutuna sahip ön yüz görüntülerinin kullanıldığını göstermektedir.


Şartlı olasılık, her bir sınıfta sonsal (*a posteriori*) olarak sınıflandırılan deneklerin toplam çeşitliliğini, deneklerin oranını, önceden belirlenmiş bir eşik değerin ötesinde bir sonsal dağılımla sınıflandırılan test edilebilir bir tahmin ve her bir gizli sınıfta sınıflandırılan öznelerin toplam denek sayısı üzerinden her sınıfın ortalama sonsal olasılığını içeren sınıflandırma tablosunu verir. Tablo 5.5 ve Tablo 5.6. sonsal kategorinin ne kadar iyi performans gösterdiğini değerlendirmektedir. Çıktı

vektöründeki tekrarlanan ölçümlerin vektörü ile, sonsal sınıflandırma ve sınıflandırma tablosu, son sınıf üyelik olasılıklarından oluşturulur. Şekil 5.22 ve Şekil 5.24, deney 1 ve 2 performans değerlendirmesi için en yüksek değere sahip her sınıf için sonsal dağılımı göstermektedir.


Bir katılımcının yüzünü diğeriyle eşleştirmek ve eşleşip eşleşmediğini belirlemek, yüz doğrulama olarak bilinir. Bire bir eşleşme kullanılır. Yüz doğrulamada, bir yüz haritası oluşturmak, bunu bir kimlik fotoğrafıyla eşleştirmek ve kişinin açıkça iddia ettiği kişi olup olmadığını değerlendirmek için makine öğrenmesi kullanılır. Yüz doğrulama prosedürü, kullanıcının farkında olduğu bir şeydir. Algoritmalar sakal bırakılan veya zorlayıcı ortam durumlarında bile, bir görünümün ayırt edici unsurlarını yakalayabilir ve yüzleri tanımlayabilir. Deney 1 ve 2'deki her sınıf için doğrulama sonuçları Şekil 5.23 ve şekil 5.25'da gösterilmiştir. Tüm sonuçlar doğrulama oranına dayalı olarak elde edilmiştir. Sistemin istikrarlı ve güvenilir performans göstermesini sağlayan ve uyarlanabilir bir eşik değer sisteme eklenmelidir.

Tablo 5.5 Deney 1’deki her sınıf için sonsal sınıflandırma sonuçları

	C_A	C_A1	C_B	C_C	C_D	C_G	C_H	C_K
C_A	%99,77	%0,05	%0,02	%0,00	%0,01	%0,00	%0,15	%0,00
C_B	%0,00	%0,01	%99,99	%0,00	%0,00	%0,00	%0,00	%0,00
C_C	%0,00	%0,04	%0,11	%95,26	%0,05	%4,44	%0,00	%0,10
C_D	%2,04	%0,11	%0,17	%0,43	%58,15	%27,66	%0,54	%10,90
C_G	%0,01	%0,03	%0,01	%0,24	%2,82	%96,82	%0,00	%0,07
C_G1	%0,03	%0,07	%0,02	%0,38	%0,53	%98,68	%0,08	%0,21
C_H	%0,67	%0,11	%0,08	%0,05	%0,04	%0,02	%99,02	%0,01
C_K	%0,02	%0,00	%0,00	%0,01	%0,02	%0,06	%0,00	%99,89
C_K1	%0,02	%0,00	%0,00	%0,02	%0,02	%0,41	%0,00	%99,53




Şekil 5.22 Deney 1’de performans değerlendirme için en yüksek değerli sonsal dağılım




Şekil 5.23 Deney 1’deki her sınıf için doğrulama sonuçları

Tablo 5.6 Deney 2’deki her sınıf için sonsal sınıflandırma sonuçları

	C_A	C_A1	C_B	C_C	C_D	C_G	C_H	C_K
C_A	%97,63	%0,22	%0,11	%0,02	%0,61	%0,01	%1,39	%0,01
C_B	%3,09	%3,51	%71,28	%8,69	%5,14	%4,73	%2,36	%1,20
C_C	%0,05	%3,96	%31,32	%52,60	%10,05	%2,00	%0,00	%0,02
C_C1	%0,15	%0,17	%1,08	%87,95	%0,50	%6,54	%0,06	%3,55
C_D	%16,24	%0,41	%0,21	%0,72	%50,27	%2,37	%26,16	%3,62
C_H	%0,46	%0,10	%0,01	%0,03	%0,01	%0,03	%99,33	%0,03
C_H1	%3,62	%0,05	%0,00	%0,01	%0,01	%0,02	%96,24	%0,05
C_K	%0,11	%0,04	%0,10	%6,86	%1,19	%32,09	%0,12	%59,49
C_U	%2,05	%1,23	%0,54	%32,78	%2,88	%44,88	%10,82	%4,82
C_Z	%3,55	%0,28	%0,04	%1,44	%1,24	%6,10	%60,22	%27,13



Şekil 5.24 Deney 2’de performans değerlendirme için en yüksek değerli sonsal dağılım



Şekil 5.25 Deney 2'deki her sınıf için doğrulama sonuçları

Deney 1'deki çeşitli yüz ifadeleri ve küçük ölçekli sağa ve sola dönüşler ile ön yüz görevleri Deney 2'ye göre daha güvenli, kesin ve güvenilir bulunmuştur. Ancak, Deney 2'de hesaplanan %100 doğruluk, modelin yüzün konumu, boyutu ve çözünürlüğündeki ciddi değişikliklerin yanı sıra eğitim setindeki modelin performansını olumsuz etkileyebilecek olan yetersiz varyansa rağmen modelin bu senaryodaki yüzleri tanımlayabildiğini göstermektedir.

ESA eğitimi için daha az yüz görüntüsü içeren bir veri tabanını işlemek, büyük veri tabanlarından ve aktarım öğreniminden daha iyi olduğundan ve öznetelik çıkarımı için çoklu tanımlayıcılar kullanarak yüz doğrulamada daha etkili olduğundan, önerilen model öğrenmek için büyük veri tabanını gerektirmez, bu da daha etkili bir yöntem olarak kabul edilir.

Sonuçlar, uzaktan eğitim ve diğer alanlar için bir yüz tanıma ve yoklama uygulaması oluştururken dikkate alınması gereken zorluklar hakkında yol gösterici olmaktadır. Model veri tabanları arasındaki benzerliğe dayalı olarak oluşturulduğundan, uzaktan öğrenme bağlamında yüz tanıma modelleri ile gerçek dünya uygulaması arasındaki doğabilecek farklılıklar konusunda bu çalışmada kullanılan yöntem dikkate alınmalıdır.

Bu bölümde, çeşitli ağ tasarım yöntemlerinden ilham alan Indepthnet adlı yüksek performanslı yüz tanıma modeline sahip benzersiz bir derin sinir ağı sunulmuştur.

Model doğrulama için seçilen veri setleri yüz tanıma ve uzaktan eğitim gereksinimlerine uygundur. Farklı yüz tanıma zorluklarına sahip dört veri tabanı üzerinde yapılan testler, bu çalışmada geliştirilen Indepthnet'in doğruluk açısından verimli olduğunu ve modelin etkililiğinin diğer derin yüz tanıma ağlarının çoğuyla benzer olduğunu göstermiştir. Ayrıca yüz tanıma ve yoklama için yeni bir ESA modeli ve yöntemi sunulmuştur. Uzaktan eğitimde yüz tanıma uygulamalarında çevrimiçi olarak mevcut olan eğitim verilerinin elde edilmesinin zorluğuyla karşılaşmaktadır. Veri dönüştürme ve çoğaltmayı kullanarak bu sorunun nasıl çözüleceği gösterilmiştir. Yüz özniteliği, önerilen ESA'dan çıkarılmışı ve sınırlı veri tabanları ve daha düşük yüz tanıma hataları için uygun olan Softmax ve Destek Vektör Makinesi kullanılarak eğitilmiştir. Tüm veri tabanları için, gerçek zamanlı sistemlerde yüz tanımayı iyileştirmek için doğrulama aşamasını destekleyen Destek Vektör Makinesi kullanmanın faydaları vurgulanmaktadır. Bu tezde uzaktan eğitim kaydında başarıyla kullanılabilecek, yüz tanıma ve yoklama zorluklarının üstesinden gelmeye uygun bir yüz tanıma modeli sunulmuştur.

Son olarak, geliştirilen model diğer sınıflandırma görevlerine de katkıda bulunabilir. Yüz tanıma ve yoklama mimarisi, uzaktan yapılması gereken herhangi bir iş için kullanıma uygundur. Ayrıca, özellikle mevcut ve gelecekteki aşamalarda, toplantılar ve kapalı bir yerde çalışmanın getirdiği kısıtlamalar nedeniyle bazı kurumlarda kullanılabilir. Model, ilerleyen zamanlarda uzaktan eğitimde duygu tanıma için kullanılarak öğrenme süreçlerine katkı sağlayabilir.

6. SONUÇLAR ve ÖNERİLER

Yüz biyolojik özellikleri başta olmak üzere birçok avantajı nedeniyle yüz tanıma tekniklerinin kullanımı giderek artmaktadır. İnsan yüzünün biyolojik özellikleri değiştirilemez ve yüz görüntülerinin kullanımı kolaydır. Bu nedenle yüz tanıma uzaktan eğitim, güvenlik ve sosyal ağlar dahil birçok sistemde en değerli biyometrik yöntem olarak kabul edilir. Bununla birlikte, poz, aydınlatma ve yüz ifadelerindeki varyasyonlar ve oklüzyon düşünüldüğünde yüz tanıma algoritmalarının geliştirilmesi zorlaşmaktadır.

Bu tezde, bu sorunları ele almak amacıyla yüz tanıma için yeni modeller ve algoritmalar önerilmiştir. Birkaç yaygın kullanılan yüz veri setinde, bu yaklaşım önceki algoritmaları geride bırakan bir performans göstermiştir. İlk olarak, yüz görüntüsü görünümünü belirli bir değere bağlı olarak farklı düzeylere ayırmak için yeni bir yöntem sunulmuştur. Bu yöntem yüz görünümü ve diğer alanlarda büyük önem taşımaktadır.

Ardından, çoklu tanımlayıcı (MD) adında yeni bir yüz görüntüsü tanımlayıcısı önerilmiştir. MD, yüz özneteliği ayrıntılarını kodlamak için farklı dağılımları etkin bir şekilde uygulamaktadır. Bu nedenle, yüz tanımlamaya yönelik belirgin iyileştirmelere sahiptir. Yüz tanıma performansını artırmak için farklı görünümelerde ve ayrıntılarda yüz özneteliklerini kodlamak için modelleri eşleştirmek üzere tanımlayıcı verimli bir şekilde genişletilmiştir. MD modelinin, yüz tanıma için mevcut yüz tabanlı tanımlayıcı modellerin çoğundan daha iyi performans gösterdiği görülmüştür.

Ayrıca, yapay zeka derin öğrenmesi ile yüz görüntüsünü tanımlamak için dört katmanı kullanarak üst düzey öznetelik çıkarımına dayalı bir model geliştirilmiştir. Dört katmanlı yapı, üç yüksek seviye ve daha derine inmek için bir katman içerdiğinden yüz tanıma için çok önemlidir. Bu model, özneteliklerin üst düzey özetleri üzerinde çalışmakta ve farklı yüz tanıma zorluklarını içeren koşullarda ilginç sonuçlar elde etmektedir. Yöntemin, mevcut birçok modelden daha iyi performans göstererek başarılı sonuçlar elde ettiği ortaya konulmuştur.

Tüm bunlara ek olarak, yapılan arařtırmaların ışığında, daha derin katmanları ve blokları arařtırmak için yeni bir derin öğrenme modeli olan Indeptnet önerilmiřtir. Yeni model, performansını ve güvenilirliğini artırmak için en son yöntemlere dayanmaktadır. Ağ altyapısı, bloğun nihai çıktısını bitirmek için ortalama ortaklamanın erken katmandan önce geldiđi ve genişletilmiř bloğun hem ortalama hem de maksimum ortaklamayı içerdii bir öğrenme yapısına sahiptir. Model, bloğun önceki özniteliđini maksimum ve ortalama özniteliđi ile bir sonraki blođa itmektedir. Model, neredeyse tüm veri tabanlarında önemli sonuçlar elde etmiř ve mevcut en son teknolojiye sahip yöntemlerden daha iyi performans göstermiřtir.

Yüz tanıma ve doğrulama gibi zorluklar ve sınırlı eğitim verilerinin üstesinden gelmek için uzaktan eğitimde yüz tanıma ve yoklama için geliştirilen modelleri genişletilmiřtir. Bu çalışmada, çeřitli ağ oluřturma yöntemlerinden ilham alan, yüz tanıma yüksek performans gösteren bir modele sahip yeni bir derin sinir ađı olan Indepthnet19 önerilmiřtir. Model doğrulama için seçilen veri tabanları hem yüz tanıma hem de uzaktan eğitim için uygundur. Farklı yüz tanımlama sorunlarına sahip dört veri tabanı üzerinde yapılan testlere göre Indepthnet19 yeterli doğruluk düzeyine ve mevcut derin yüz tanıma ađlarının çođuyla benzer bir etkililik düzeyine sahiptir. Ek olarak, yeni bir ESA yüz tanıma ve yoklama modeli gösterilmiřtir. Uzaktan eğitimde yüz tanıma, çevrimiçi olarak kolayca erişilebilen eğitim verileri bulmanın zorluklarından etkilenmektedir. Bu zorluğun üstesinden gelmek için veri dönüřtürme ve çoğaltmadan nasıl faydalanılacađı gösterilmektedir. Önerilen ESA’da yüz öznitelikleri, küçük veri tabanları ve düşük yüz tanıma hata oranları için kullanılıř olan Softmax ve Destek Vektör Makinesi kullanılarak çıkarılmıř ve eğitilmiřtir. Gerçek zamanlı sistemlerde yüz tanımayı geliřtirmek için tüm veri tabanlarında doğrulama adımını geliřtiren Destek Vektör Makinesini kullanmanın faydaları vurgulanmalıdır. Bu tezde, uzaktan eğitim kaydında başarıyla kullanılabilen ve yüz tanıma ve yoklama sorunlarının üstesinden gelebilecek olan bir yüz tanıma modeli geliřtirilmiřtir. Bu modelden diđer sınıflandırma problemlerinde de yararlanılabilir. Toplanma ve kapalı bir alanda çalışmaya getirilen sınırlamalar nedeniyle, yüz tanıma ve yoklama mimarisi, uzaktan yapılması gereken herhangi bir faaliyet için uygundur ve özellikle mevcut ve gelecekteki aşamalarda bazı kurumlarda kullanılabilir. Gelecekte, bu model uzaktan eğitimde duygu tanıma kullanılarak öğrenme süreçlerine katkı sağlayabilir. MD

modelleri gelecek alıřmalarda farklı veri daėılımlarına sahip setlerle kullanılabilir. Önerilen öznitelik ıkarma ve evriřimsel sinir aėı entegrasyonu, doėruluėu ve performansı artırabilmektedir.

Gelecekte gerek dnyadaki bilgisayarlı görde uygulamak iin biyometrik yz tanıma yntemleri geliřtirilmeye devam etmelidir. Yapay zeka ve derin öėrenmede, veri üzerinde alıřmanın yeni modeller tasarlamaktan daha önemli olduėu sonucuna varılmıřtır. Yapay zekanın geleceėinde mevcut modelleri kullanan daha fazla yntem geliřtirilebilir ve bu yntemlerin gerek dnya sistemlerinde kullanılması iin diėer alanlarda fırsatlar yaratılabilir. Bu tez boyunca elde edilen bulgular, gerek dnya uygulamalarında kullanılmak üzere yz tanıma yntemlerinin geliřtirilmesine olanak tanır. Yz tanımada, ok eřitli etiketli verilere eriřilebilir. Daha etkili öznitelik ıkarma modelleri oluřturan ve birden ok veri kaynaėını ve mimariyi birleřtiren yeni yntemler arayıřına devam edilmelidir.

KAYNAKLAR

- Abdullah, I. A., & Stephan, J. J. (2021). A Survey of Face Recognition Systems. *Ibn AL-Haitham Journal For Pure and Applied Science*, 34(2), 144–160.
- Abduraximovich, K. K. (2021). Teaching based on distance education technology as a complete pedagogical problem. *Academica: An International Multidisciplinary Research Journal*, 11(1), 1199–1203. <https://doi.org/10.5958/2249-7137.2021.00198.1>
- Abiero, J., Kimwele, M., & Chemwa, G. (2022). Face Recognition Under Partial Occlusion: A Detection and Exclusion of Occluded Face Regions Approach. *Mediterranean Conference on Pattern Recognition and Artificial Intelligence*, 18–32.
- Abushanap, S. A., Abdalla, A. M., Tamimi, A. A., & Alzu'bi, S. (2021). A Survey of Human Face Recognition for Partial Face View. *2021 International Conference on Information Technology (ICIT)*, 571–576.
- Agarwal, L., Mukim, M., Sharma, H., Bhandari, A., & Mishra, A. (2021). Face Recognition Based Smart and Robust Attendance Monitoring using Deep CNN. *2021 8th International Conference on Computing for Sustainable Global Development (INDIACom)*, 699–704.
- Ahmed, F., Hossain, E., Bari, A. S. M. H., & Shihavuddin, A. S. M. (2011). Compound local binary pattern (CLBP) for robust facial expression recognition. *2011 IEEE 12th International Symposium on Computational Intelligence and Informatics (CINTI)*, 391–395.
- Ahonen, T., Rahtu, E., Ojansivu, V., & Heikkila, J. (2008). Recognition of blurred faces using Local Phase Quantization. *2008 19th International Conference on Pattern Recognition*, 1–4. <https://doi.org/10.1109/ICPR.2008.4761847>
- Akheel, T. S., Shree, V. U., & Mastani, S. A. (2021). Stochastic gradient descent linear collaborative discriminant regression classification based face recognition. *Evolutionary Intelligence*, 1–15.
- Akmal Abdullaev, M. H. (2020). Innovative Distance Learning Technologies. *Journal of Critical Reviews*, 7(11). <https://doi.org/10.31838/jcr.07.11.57>
- Ali, W., Tian, W., Din, S. U., Iradukunda, D., & Khan, A. A. (2021). Classical and modern face recognition approaches: a complete review. *Multimedia Tools and Applications*, 80(3), 4825–4880.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Van Esesn, B. C., Awwal, A. A. S., & Asari, V. K. (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. *ArXiv Preprint ArXiv:1803.01164*.

- Anusha, M., & Kiruthika, P. (2022). A Comparative Study on Augmented Analytics Using Deep Learning Techniques. In *Ubiquitous Intelligent Systems* (pp. 135–142). Springer.
- Athreya, S. M., Shreevari, S. P., Siddesh, A., Kiran, S., & Chetana, H. T. (2021). A Survey on Partially Occluded Faces. In *Evolutionary Computing and Mobile Sustainable Networks* (pp. 61–67). Springer.
- Aydin, E., & Erol, S. (2021). The views of Turkish language teachers on distance education and digital literacy during covid-19 pandemic. *International Journal of Education and Literacy Studies*, 9(1), 60–71.
- Badave, H., & Kuber, M. (2021). Performance Analysis of Light Illuminations and Image Quality Variations and its Effects on Face Recognition. *2021 International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT)*, 28–33.
- Balas, V. E., Roy, S. S., Sharma, D., & Samui, P. (2019). *Handbook of deep learning applications* (Vol. 136). Springer.
- Barina, D. (2016). *Gabor Wavelets in Image Processing*. <http://arxiv.org/abs/1602.03308>
- Basha, S. H. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112–119.
- Ben Fredj, H., Bouguezzi, S., & Souani, C. (2021). Face recognition in unconstrained environment with CNN. *The Visual Computer*, 37(2), 217–226.
- Bensenane, H., & Keche, M. (2016). Face recognition using angular radial transform. *Journal of King Saud University–Computer and Information Sciences Computer and Information Sciences*.
- Bhangale, K., Ingle, P., Kanase, R., & Desale, D. (2021). Multi-view Multi-pose Robust Face Recognition Based on VGGNet. *International Conference on Image Processing and Capsule Networks*, 414–421.
- Bharadwaj, R. R., Belavadi, S., Gadicherla, S., Vinay, A., Natarajan, S., & Murthy, K. N. B. (2019). XNORNet and Minimum Barrier Detection for Efficient Face Recognition. *Procedia Computer Science*, 152, 74–83.
- Bhavsar, H., & Panchal, M. H. (2012). A review on support vector machine for data classification. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 1(10), 185–189.
- Biswas, R., & Blanco-Medina, P. (2021). State of the Art: Face Recognition. *ArXiv Preprint ArXiv:2108.11821*.
- Brandoni, D., & Simoncini, V. (2020). Tensor-Train decomposition for image recognition. *Calcolo*, 57(1), 1–24.

- Buczowski, P., Sobkowicz, A., & Kozłowski, M. (2018). Deep learning approaches towards book covers classification. *ICPRAM*, 309–316.
- Buduma, N., Buduma, N., & Papa, J. (2022). *Fundamentals of deep learning*. “O’Reilly Media, Inc.”
- Casacchia, M., Cifone, M. G., Giusti, L., Fabiani, L., Gatto, R., Lancia, L., Cinque, B., Petrucci, C., Giannoni, M., & Ippoliti, R. (2021). Distance education during COVID 19: an Italian survey on the university teachers’ perspectives and their emotional conditions. *BMC Medical Education*, 21(1), 1–17.
- Chandra, M. A., & Bedi, S. S. (2021). Survey on SVM and their application in image classification. *International Journal of Information Technology*, 13(5), 1–11.
- Chen, C., & Zhou, X. (2022). Collaborative representation-based fuzzy discriminant analysis for Face recognition. *The Visual Computer*, 1–11.
- Chen, Y., Tao, X., Xiong, C., & Yang, J. (2018). An Improved method of Two Stage Linear Discriminant Analysis. *KSII Transactions on Internet and Information Systems (TIIS)*, 12(3), 1243–1263.
- Da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). Artificial neural networks. *Cham: Springer International Publishing*, 39.
- Dalvi, J., Bafna, S., Bagaria, D., & Virnodkar, S. (2022). A Survey on Face Recognition Systems. *ArXiv Preprint ArXiv:2201.02991*.
- Daniel, H. (2021). An Analysis of One-Shot Augmented Learning: A Face Recognition Case Study. *New Trends in Disruptive Technologies, Tech Ethics and Artificial Intelligence: The DITTET Collection*, 1410, 55.
- David G. Lowe. (1999). Object Recognition from Local Scale-Invariant Features. *Proceedings of the Seventh IEEE International Conference on Computer Vision*, 1150–1157. https://doi.org/doi.org/10.1007/978-3-642-15561-1_56
- Deng, L., & Liu, Y. (2018). *Deep learning in natural language processing*. Springer.
- Destefanis, G., Barge, M. T., Brugiapaglia, A., & Tassone, S. (2000). The use of principal component analysis (PCA) to characterize beef. *Meat Science*, 56(3), 255–259. [https://doi.org/https://doi.org/10.1016/S0309-1740\(00\)00050-4](https://doi.org/https://doi.org/10.1016/S0309-1740(00)00050-4)
- Devan, P. A. M., Venkateshan, M., Vignesh, A., & Karthikraj, S. R. M. (2017). Smart attendance system using face recognition. *Advances in Natural and Applied Sciences*, 11(7), 139–145.
- Dhal, K. G., Das, A., Ray, S., Gálvez, J., & Das, S. (2021). Histogram equalization variants as optimization problems: a review. *Archives of Computational Methods in Engineering*, 28(3), 1471–1496.
- Ding, C., & Tao, D. (2016). A Comprehensive Survey on Pose-Invariant Face

- Recognition. *ACM Transactions on Intelligent Systems and Technology*, 7(3), 1–42. <https://doi.org/10.1145/2845089>
- Ediz, Ç. (2021). Identification with Face Recognition Methods in Real Life Applications. *International Journal of Engineering Technologies*.
- Erakın, M. E., Demir, U., & Ekenel, H. K. (2021). On recognizing occluded faces in the wild. *2021 International Conference of the Biometrics Special Interest Group (BIOSIG)*, 1–5.
- Gasparin, A., Lukovic, S., & Alippi, C. (2022). Deep learning for time series forecasting: The electric load case. *CAAI Transactions on Intelligence Technology*, 7(1), 1–25.
- Gavel, H., & Mehta, A. K. (2021). A Novel Approach of Multi-Objective Based Feature Selection Method for Face Recognition. *2021 2nd Global Conference for Advancement in Technology (GCAT)*, 1–6.
- Gavriell, B., Fauzan, F., Ardian, N., & Suryaningrum, K. M. (2021). Implementation of Face Recognition Method for Attendance in Class. *2021 1st International Conference on Computer Science and Artificial Intelligence (ICCSAI)*, 1, 148–153.
- Gawande, U., Joshi, P., Ghatwai, S., Nemade, S., Balkothe, S., & Shrikhande, N. (2022). Efficient Attendance Management System Based on Face Recognition. In *ICT Systems and Sustainability* (pp. 113–121). Springer.
- Georgiou, T., Liu, Y., Chen, W., & Lew, M. (2020). A survey of traditional and deep learning-based feature descriptors for high dimensional data in computer vision. *International Journal of Multimedia Information Retrieval*, 9(3), 135–170. <https://doi.org/10.1007/s13735-019-00183-w>
- Ghorbani, M., Targhi, A. T., & Dehshibi, M. M. (2015). HOG and LBP: Towards a robust face recognition system. *2015 Tenth International Conference on Digital Information Management (ICDIM)*, 138–141. <https://doi.org/10.1109/ICDIM.2015.7381860>
- Giovani, V., Johansen, I., Ashilla, D. A., & Hanafiah, N. (2021). Study on Face Recognition Techniques. *2021 1st International Conference on Computer Science and Artificial Intelligence (ICCSAI)*, 1, 301–306.
- Goel, L. (2022). A novel approach for face recognition using biogeography based optimization with extinction and evolution. *Multimedia Tools and Applications*, 1–28.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Gupta, D., Khanna, A., Kansal, V., Fortino, G., & Hassanien, A. E. (Eds.). (2022). *Proceedings of Second Doctoral Symposium on Computational Intelligence* (Vol. 1374). Springer Singapore. <https://doi.org/10.1007/978-981-16-3346-1>

- Gupta, S., Thakur, K., & Kumar, M. (2021). 2D-human face recognition using SIFT and SURF descriptors of face's feature regions. *The Visual Computer*, 37(3), 447–456.
- Gupta, Y., Prasad, A., Touti, S., Sachdev, K., Jaiswal, V., & Naranje, V. (2021). Real-time face recognition: A survey. *2021 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, 430–434.
- Hadiprakoso, R. B., & Buana, I. K. S. (2021). Performance Comparison of Feature Extraction and Machine Learning Classification Algorithms for Face Recognition. *The IJICS (International Journal of Informatics and Computer Science)*, 5(3), 250–257.
- Han, C., Shan, S., Kan, M., Wu, S., & Chen, X. (2022). Personalized Convolution for Face Recognition. *International Journal of Computer Vision*, 1–19.
- Hassaballah, M., & Awad, A. I. (2020). *Deep learning in computer vision: principles and applications*. CRC Press.
- Hassanpour, H., & Ghasemi, M. (2021). A three-stage filtering approach for face recognition. *International Journal of Engineering*, 34(8), 1856–1864.
- He, G., & Jiang, Y. (2022). Real-time Face Recognition using SVM, MLP and CNN. *2022 International Conference on Big Data, Information and Computer Network (BDICN)*, 762–767.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Hosny, K. M., Abd Elaziz, M., & Darwish, M. M. (2021). Color face recognition using novel fractional-order multi-channel exponent moments. In *Neural Computing and Applications* (Vol. 33, Issue 11, pp. 5419–5435). <https://doi.org/10.1007/s00521-020-05280-0>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700–4708.
- Huang, Y.-H., & Chen, H. H. (2022). Deep Face Recognition for Dim Images. *Pattern Recognition*, 108580.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). *SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size*. <http://arxiv.org/abs/1602.07360>
- Jain, T., & Yadav, J. (2022). An Enhanced Support Vector Machine for Face Recognition in Fisher Subspace. *Proceedings of Second Doctoral Symposium on Computational Intelligence*, 393–407.
- Javed Mehedi Shamrat, F. M., Ghosh, P., Tasnim, Z., Khan, A. A., Uddin, M., &

- Chowdhury, T. R. (2022). Human Face Recognition Using Eigenface, SURF Method. In *Pervasive Computing and Social Networking* (pp. 73–88). Springer.
- Jiang, W., Ye, L., Yi, Z., & Peng, C. (2022). A new occluded face recognition framework with combination of both Deocclusion and feature filtering methods. *Multimedia Tools and Applications*, 1–30.
- Jiang, X., Pang, Y., Li, X., Pan, J., & Xie, Y. (2018). Deep neural networks with elastic rectified linear units for object recognition. *Neurocomputing*, 275, 1132–1139.
- Jolly, S., Iwana, B. K., Kuroki, R., & Uchida, S. (2018). How do convolutional neural networks learn design? *2018 24th International Conference on Pattern Recognition (ICPR)*, 1085–1090.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, J. S. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Kamra, A. (2021). A Survey on Face Analysis and Its Applications (Face Recognition & Facial Age Estimation). *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(2), 462–466.
- Karanwal, S. (2021). A comparative study of 14 state of art descriptors for face Recognition. *Multimedia Tools and Applications*, 80(8), 12195–12234.
- Karanwal, S., & Diwakar, M. (2021a). Neighborhood and center difference-based-LBP for face recognition. *Pattern Analysis and Applications*, 24(2), 741–761.
- Karanwal, S., & Diwakar, M. (2021b). OD-LBP: Orthogonal difference-local binary pattern for Face Recognition. *Digital Signal Processing*, 110, 102948.
- Khan, S., Rahmani, H., Shah, S. A. A., & Bennamoun, M. (2018). A guide to convolutional neural networks for computer vision. *Synthesis Lectures on Computer Vision*, 8(1), 1–207.
- Khokhar, M. S., Ayoub, M., Zakria, J., & Rasheed, W. (2021). Efficient Face Re-Identification through PSO Based Adaptive Deep Learning Models. *Journal of Independent Studies and Research Computing*, 19(2), 18–35.
- Khong, V., Zeng, Z., Fang, L., & Wang, S. (2021). One-Shot Face Recognition Based on Multiple Classifiers Training. *2021 13th International Conference on Machine Learning and Computing*, 432–437.
- Kim, K. G. (2016). Book review: Deep learning. *Healthcare Informatics Research*, 22(4), 351–354.
- Kim, P. (2017). Matlab deep learning. *With Machine Learning, Neural Networks and Artificial Intelligence*, 130(21).
- Koonce, B. (2021). SqueezeNet. In *Convolutional Neural Networks with Swift for Tensorflow* (pp. 73–85). Springer.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- Kumar, M., & Hussaini, T. (2021). Face Recognition Algorithm based on Traditional and Artificial Intelligence: A Systematic Review. *2021 International Conference on Intelligent Technologies (CONIT)*, 1–5.
- Kurita, T. (2019). Principal Component Analysis (PCA). In *Computer Vision: A Reference Guide* (pp. 1–4). Springer International Publishing. https://doi.org/10.1007/978-3-030-03243-2_649-1
- Lahitani, A. R., Permanasari, A. E., & Setiawan, N. A. (2016). Cosine similarity to determine similarity measure: Study case in online essay assessment. *2016 4th International Conference on Cyber and IT Service Management*, 1–6. <https://doi.org/10.1109/CITSM.2016.7577578>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lee, C.-Y., Xie, S., Gallagher, P., Zhang, Z., & Tu, Z. (2015). Deeply-Supervised Nets. In G. Lebanon & S. V. N. Vishwanathan (Eds.), *Proceedings of the Eighteenth International Conference on Artificial Intelligence and Statistics* (Vol. 38, pp. 562–570). PMLR. <https://proceedings.mlr.press/v38/lee15a.html>
- Lee, P. (2021). *Single-Sample Face Recognition for Attendance Record*. Tunku Abdul Rahman University College.
- Li, D. (2021). Deep Learning Technology Based on Intelligent Teaching in Social Psychology Courses. *International Journal of Emerging Technologies in Learning*, 16(24), 40–56. <https://doi.org/10.3991/ijet.v16i24.27255>
- Li, F. F., Karpathy, A., & Johnson, J. (2016). Lecture 7: Convolutional Neural Networks. URL: [Http://Cs231n.Stanford.Edu/Slides/2016/Winter1516_lecture7.Pdf](http://Cs231n.Stanford.Edu/Slides/2016/Winter1516_lecture7.Pdf) (Visited on 2018-03-26).
- Li, P., Tu, S., & Xu, L. (2022). Deep Rival Penalized Competitive Learning for low-resolution face recognition. *Neural Networks*.
- Liang, H., Gao, J., & Qiang, N. (2021). A novel framework based on wavelet transform and principal component for face recognition under varying illumination. *Applied Intelligence*, 51(3), 1762–1783.
- Liermann, V., Li, S., & Schaudinnus, N. (2019). Deep learning: An introduction. In *The Impact of Digital Transformation and Fintech on the Finance Professional* (pp. 305–340). Springer.
- Lindeberg, T. (2012). Scale Invariant Feature Transform. *Scholarpedia*, 7(5), 10491. <https://doi.org/10.4249/scholarpedia.10491>
- Liu, B.-D., Shen, B., Gui, L., Wang, Y.-X., Li, X., Yan, F., & Wang, Y.-J. (2016).

- Face recognition using class specific dictionary learning for sparse representation and collaborative representation. *Neurocomputing*, 204, 198–210.
- Liu, F., Wang, F., Ding, Y., & Yang, S. (2021). SOM-based binary coding for single sample face recognition. *Journal of Ambient Intelligence and Humanized Computing*, 1–11.
- Liu, R., Liu, Y., Wang, Z., & Tian, H. (2022). Research on face recognition technology based on an improved LeNet-5 system. *2022 International Seminar on Computer Science and Engineering Technology (SCSET)*, 121–123.
- Liu, Y., Guo, Y., Georgiou, T., & Lew, M. S. (2018). Fusion that matters: convolutional fusion networks for visual recognition. *Multimedia Tools and Applications*, 77(22), 29407–29434. <https://doi.org/10.1007/s11042-018-5691-4>
- Lu, J., Plataniotis, K. N., & Venetsanopoulos, A. N. (2003). Face recognition using LDA-based algorithms. *IEEE Transactions on Neural Networks*, 14(1), 195–200. <https://doi.org/10.1109/TNN.2002.806647>
- Luo, J., Ma, Y., Takikawa, E., Lao, S., Kawade, M., & Lu, B.-L. (2007). Person-specific SIFT features for face recognition. *2007 IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP '07*, 2, II–593.
- Luo, M., Cao, J., Ma, X., Zhang, X., & He, R. (2021). FA-GAN: face augmentation GAN for deformation-invariant face recognition. *IEEE Transactions on Information Forensics and Security*, 16, 2341–2355.
- Ma, L. (2021). Face Recognition of Intelligent Building based on Super-Resolution Reconstruction of Visual Image. *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 895–900.
- Madhavan, S., & Kumar, N. (2021). Incremental methods in face recognition: a survey. *Artificial Intelligence Review*, 54(1), 253–303.
- Mangasarian, O. L., & Musicant, D. R. (2001). Lagrangian support vector machines. *Journal of Machine Learning Research*, 1(Mar), 161–177.
- Marenkov, A. N., Gelagaev, T. M., & Kuznetsova, V. Y. (2021). Application of face recognition technologies in access control and management systems. *IOP Conference Series: Materials Science and Engineering*, 1069(1), 12029.
- Mclaughlin, N., Ming, J., & Crookes, D. (2016). *Occlusion Robust Face Recognition* (pp. 1–13).
- Méndez-Llanes, N., Castillo-Rosado, K., Méndez-Vázquez, H., & Tistarelli, M. (2022). On the use of local fixations and quality measures for deep face recognition. *IEEE Transactions on Biometrics, Behavior, and Identity Science*.
- Michael Calonder, Vincent Lepetit, Christoph Strecha and P. F. (2010). BRIEF: Binary Robust Independent Elementary Features. (Eds) *Computer Vision –*

- ECCV 2010. ECCV 2010. *Lecture Notes in Computer Science*, 6314. https://doi.org/https://doi.org/10.1007/978-3-642-15561-1_56
- Min Lin, Qiang Chen, S. Y. (2014). Network In Network. *Neural and Evolutionary Computing*.
- Mishra, V., Mishra, R., Rani, R., & Khan, I. (2022). Attendance Management System Using Face Recognition. In *Advances in Computational Intelligence and Communication Technology* (pp. 47–59). Springer.
- Modi, P., & Patel, S. (2022). A State-of-the-Art Survey on Face Recognition Methods. *International Journal of Computer Vision and Image Processing (IJCVIP)*, 12(1), 1–19.
- Mohamed, A. A., Bilal, K. H., & Elmutasim, I. E. (2021). Face Recognition by Artificial Neural Network Using MATLAB. *2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA)*, 686–690.
- Mu, D., & Guo, W. (2022). Impact of Students' Online Learning Burnout on Learning Performance – the Intermediary Role of Game Evaluation. *International Journal of Emerging Technologies in Learning (IJET)*, 17(02), 239–253. <https://doi.org/10.3991/ijet.v17i02.28555>
- Nabat, Z. M., Mahdi, M. T., & Shnain, S. A. H. (2022). Face Recognition Method based on Support Vector Machine and Rain Optimization Algorithm (ROA). *Webology*, 19(1).
- Najafi Khanbebin, S., & Mehrdad, V. (2021). Local improvement approach and linear discriminant analysis-based local binary pattern for face recognition. *Neural Computing and Applications*, 33(13), 7691–7707.
- Nguyen, H. V., & Bai, L. (2011). *Cosine Similarity Metric Learning for Face Verification* (pp. 709–720). https://doi.org/10.1007/978-3-642-19309-5_55
- Norouzi, M. (2022). *A Survey on Face Recognition Based on Deep Neural Networks*.
- Ozdemir, D., & Ugur, M. E. (2021a). A Model Proposal On The Determination Of Student Attendance In Distance Education With Face Recognition Technology. *Turkish Online Journal of Distance Education*, 22(1), 19–32. <https://doi.org/10.17718/TOJDE.849872>
- Ozdemir, D., & Ugur, M. E. (2021b). Model Proposal On The Determination Of Student Attendance In Distance Education With Face Recognition Technology. *Turkish Online Journal of Distance Education*, 22(1), 19–32.
- Pan, J.-S., Wang, X., Feng, Q., & Chu, S.-C. (2020). A kernel-based probabilistic collaborative representation for face recognition. *IEEE Access*, 8, 37946–37957.
- Pandey, M., & Gupta, A. (2022). A Review on Face Recognition Methods Using Infrared Images. *Proceedings of International Conference on Intelligent Cyber-Physical Systems*, 367–377.

- Pandita, A. (2021). *Deep Face Recognition and Rejection of Unknown Faces*. University of Massachusetts Boston.
- Parkhi, O. M., Vedaldi, A., & Zisserman, A. (2015). Deep Face Recognition. *Proceedings of the British Machine Vision Conference 2015*, 41.1-41.12. <https://doi.org/10.5244/C.29.41>
- Pei, Z., Xu, H., Zhang, Y., Guo, M., & Yang, Y.-H. (2019). Face Recognition via Deep Learning Using Data Augmentation Based on Orthogonal Experiments. *Electronics*, 8(10), 1088. <https://doi.org/10.3390/electronics8101088>
- Pellegrini, T. (2015). Comparing SVM, Softmax, and shallow neural networks for eating condition classification. *Sixteenth Annual Conference of the International Speech Communication Association*.
- Peña, A., Morales, A., Serna, I., Fierrez, J., & Lapedriza, A. (2021). Facial expressions as a vulnerability in face recognition. *2021 IEEE International Conference on Image Processing (ICIP)*, 2988–2992.
- Qi, X., Wang, T., & Liu, J. (2017). Comparison of support vector machine and softmax classifiers in computer vision. *2017 Second International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*, 151–155.
- Rana, S., & Kisku, D. R. (2021). Face Recognition Using Siamese Network. *Proceedings of International Conference on Frontiers in Computing and Systems*, 369–376.
- Reddy, K. S., Kumar, V. V., & Reddy, B. E. (2015). Face recognition based on texture features using local ternary patterns. *International Journal of Image, Graphics and Signal Processing*, 7(10), 37.
- Reddy, N. V. M. C., & Kumar, K. (2021). Comparison of HOG and Fisherfaces Based Face Recognition System Using MATLAB. *2021 2nd International Conference for Emerging Technology (INCET)*, 1–5.
- Salamh, A. B. S., Salamah, A. A., & Halil Ibrahim Akyüz. (2021). A Study of a New Technique of the CT Scan View and Disease Classification Protocol Based on Level Challenges in Cases of Coronavirus Disease. *Radiology Research and Practice*, 2021, 1–9. <https://doi.org/10.1155/2021/5554408>
- S.K.Nazarova, G. A.Jalilova,N.S.Mukhamedova, N. F. R. (2021). Features ofDistance Learning Organization. *Annals of RSCB*, 1, 339–347.
- SAI, E. C., HUSSAIN, S. A., KHAJA, S., & SHYAM, A. (2021). Student Attendance Monitoring System Using Face Recognition. *Available at SSRN 3851056*.
- Sangeetha, V., & Prasad, K. J. R. (2006). Syntheses of Novel Derivatives of 2-Acetylfuro[2,3-a]carbazoles, Benzo[1,2-b]-1,4-thiazepino[2,3-a]carbazoles and 1-Acetyloxycarbazole-2-carbaldehydes. *ChemInform*, 37(50). <https://doi.org/10.1002/chin.200650130>

- Santurkar, S., Tsipras, D., Ilyas, A., & Madry, A. M. (2018). *How Does Batch Normalization Help Optimization*.
- Saragih, R. E., & To, Q. H. (2022). A Survey of Face Recognition based on Convolutional Neural Network. *Indonesian Journal of Information Systems*, 4(2). <https://doi.org/10.24002/ijis.v4i2.5439>
- Schroff, F., Kalenichenko, D., & Philbin, J. (2015). Facenet: A unified embedding for face recognition and clustering. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 815–823.
- Seethalakshmi, K., & Valli, S. (2022). An efficient fuzzy deep learning approach to recognize 2D faces using FADF and ResNet-164 architecture. *Journal of Intelligent & Fuzzy Systems, Preprint*, 1–10.
- Sergey Ioffe;Christian Szegedy. (2015). Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Proceedings of the 32nd International Conference on Machine Learning*, 37, 448–456.
- Shamrat, F. M. J. M., Bhowmik, S. K., Muntasim, M. F., Nibir, T. I., Chowdhury, T. R., & Thapa, S. (2021). Comparative Analysis of Human Face Recognition Using SURF and Neural Network Methods. *2021 2nd International Conference on Smart Electronics and Communication (ICOSEC)*, 984–988.
- Shao, H.-C., Liu, K.-Y., Lin, C.-W., & Lu, J. (2020). DotFAN: A Domain-transferred Face Augmentation Network for Pose and Illumination Invariant Face Recognition. *ArXiv Preprint ArXiv:2002.09859*.
- Shirindi, N., Madzima, K., & Chibaya, C. (2021). Face Recognition using PCA and constrained images. *2021 3rd International Multidisciplinary Information Technology and Engineering Conference (IMITEC)*, 1–4.
- Shreekumar, T., Sunitha, N. V, Suma, K., Sharma, S., & Mittal, P. (2022). Recognizing the Faces from Variety of Poses and Illumination. In *Smart Intelligent Computing and Applications, Volume 1* (pp. 95–101). Springer.
- Shukla, R. K., Sengar, A. S., Gupta, A., Jain, A., Kumar, A., & Vishnoi, N. K. (2021). Face Recognition using Convolutional Neural Network in Machine Learning. *2021 10th International Conference on System Modeling & Advancement in Research Trends (SMART)*, 456–461.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *ArXiv Preprint ArXiv:1409.1556*.
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14.
- Somogyi, Z. (2021). Face Recognition. In *The Application of Artificial Intelligence* (pp. 175–184). Springer.

- Song, T., Han, Y., Li, S., & Zhao, C. (2022). Grayscale-inversion and rotation invariant image description using local ternary derivative pattern with dominant structure encoding. *Expert Systems with Applications*, 191, 116327. <https://doi.org/10.1016/j.eswa.2021.116327>
- Spacek, L. (2009). *Libor Spacek's Facial Images Databases*. Computer Vision Science Research Projects. <https://cmp.felk.cvut.cz/~spacelib/faces/>
- Sun, X., Zhang, X., & Lei, L. (2022). The Effects of Online Role-play Teaching Practice on Learners' Availability for Resources. *International Journal of Emerging Technologies in Learning (IJET)*, 17(05), 4–18. <https://doi.org/10.3991/ijet.v17i05.30575>
- Suzuki, K. (2013). *Artificial neural networks: Architectures and applications*. BoD–Books on Demand.
- Tammina, S. (2019). Transfer learning using VGG-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143–150.
- Tang, S., & Shabaz, M. (2021). A new face image recognition algorithm based on cerebellum-basal ganglia mechanism. *Journal of Healthcare Engineering*, 2021.
- Tang, Y. (2013). Deep learning using linear support vector machines. *ArXiv Preprint ArXiv:1306.0239*.
- Terhörst, P., Ihlefeld, M., Huber, M., Damer, N., Kirchbuchner, F., Raja, K., & Kuijper, A. (2021). QMagFace: Simple and Accurate Quality-Aware Face Recognition. *ArXiv Preprint ArXiv:2111.13475*.
- Thomas, R. (2021). Face recognition from image patches using an ensemble of CNN-local mesh pattern networks. *2021 6th International Conference for Convergence in Technology (I2CT)*, 1–5.
- Topi, M., Timo, O., Matti, P., & Maricor, S. (2000). Robust texture classification by subsets of local binary patterns. *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*, 3, 935–938.
- Tran, C.-K., Hoa, N. T. T., Ngoan, N. T. C., & Nguyen, L.-A. (2021). SVM-based face recognition through difference of Gaussians and local phase quantization. *International Journal of Computer Theory and Engineering*, 13(1), 1–8.
- Triggs, N. D. and B., & INRIA. (2005). Histograms of oriented gradients for human detection. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR '05)*. <https://doi.org/10.1109/CVPR.2005.177>
- Truong, H. P., & Kim, Y.-G. (2018). Enhanced line local binary patterns (EL-LBP): an efficient image representation for face recognition. *International Conference on Advanced Concepts for Intelligent Vision Systems*, 285–296.
- Uchoa, V., Aires, K., Veras, R., Paiva, A., & Britto, L. (2020). Data Augmentation for

- Face Recognition with CNN Transfer Learning. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 143–148. <https://doi.org/10.1109/IWSSIP48289.2020.9145453>
- Uplaonkar, D. S., & Patil, N. (2022). A Brief Survey on Segmentation and Classification Techniques for Face Recognition. *2022 International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, 1038–1043.
- Venkatesan, R., & Li, B. (2017). *Convolutional neural networks in visual computing: a concise guide*. CRC Press.
- Verma, A., Goyal, A., Kumar, N., & Tekchandani, H. (2022). Face Recognition: A Review and Analysis. *Computational Intelligence in Data Mining*, 195–210.
- Véstias, M. P. (2021). Convolutional neural network. In *Encyclopedia of Information Science and Technology, Fifth Edition* (pp. 12–26). IGI Global.
- Vijayalakshmi, D., & Nath, M. K. (2021). A novel contrast enhancement technique using gradient-based joint histogram equalization. *Circuits, Systems, and Signal Processing*, 40(8), 3929–3967.
- Vinay, A., Hebbar, D., Shekhar, V. S., Murthy, K. N. B., & Natarajan, S. (2015). Two novel detector-descriptor based approaches for face recognition using sift and surf. *Procedia Computer Science*, 70, 185–197.
- Viola, P., & Jones, M. J. (2004). Robust Real-Time Face Detection. *International Journal of Computer Vision*, 57(2), 137–154. <https://doi.org/10.1023/B:VISI.0000013087.49260.fb>
- Voronov, V., Strelnikov, V., Voronova, L., Trunov, A., & Vovik, A. (2019). Faces 2D-recognition and identification using the HOG descriptors method. *Conference of Open Innovations Association, FRUCT*, 24, 783–789.
- Waghunde, M. P. P., Sabale, M. A. A., Tayde, M. M. P., Sawant, M. Y. B., & Chadchankar, A. S. (2021). *Application Of Face Recognition For Attendance System*.
- Walczak, S. (2018). Artificial neural networks. In *Encyclopedia of Information Science and Technology, Fourth Edition* (pp. 120–131). IGI Global.
- Wan, J., Chen, Y., & Bai, B. (2021). Joint feature extraction and classification in a unified framework for cost-sensitive face recognition. *Pattern Recognition*, 115, 107927.
- Wang, D., Wang, H., Sun, J., Xin, J., & Luo, Y. (2021). Face Recognition in Complex Unconstrained Environment with An Enhanced WVN Algorithm. *Journal of Intelligent Systems*, 30(1), 18–39.
- Wang, J., Liu, Y., Hu, Y., Shi, H., & Mei, T. (2021). Facex-zoo: A pytorch toolbox for face recognition. *Proceedings of the 29th ACM International Conference on Multimedia*, 3779–3782.

- Wani, M. A., Bhat, F. A., Afzal, S., & Khan, A. I. (2020). *Advances in Deep Learning* (Vol. 57). Springer Singapore. <https://doi.org/10.1007/978-981-13-6794-6>
- Winarno, E., Al Amin, I. H., Hadikurniawati, W., & Anwar, M. T. (2021). Attendance System Based on Face Recognition Using Hybrid Feature Extraction Method. *International Conference on Innovation in Science and Technology (ICIST 2020)*, 47–49.
- Wu, J., & Zhou, Z.-H. (2003). Efficient face candidates selector for face detection. *Pattern Recognition*, 36(5), 1175–1186.
- Xiong, J., Yu, D., Wang, Q., Shu, L., Cen, J., Liang, Q., Chen, H., & Sun, B. (2021). Application of histogram equalization for image enhancement in corrosion areas. *Shock and Vibration*, 2021.
- Yale Face Database. (n.d.). <http://vision.ucsd.edu/content/yale-face-database>
- Yallamandaiah, S., & Purnachand, N. (2022). A novel face recognition technique using Convolutional Neural Network, HOG, and histogram of LBP features. *2022 2nd International Conference on Artificial Intelligence and Signal Processing (AISP)*, 1–5.
- Yee, S. Y., Rassem, T. H., Mohammed, M. F., & Awang, S. (2020). *Face Recognition Using Laplacian Completed Local Ternary Pattern (LapCLTP)* (pp. 315–327). https://doi.org/10.1007/978-981-15-1289-6_29
- Yu, A., Wu, H., Huang, H., Lei, Z., & He, R. (2021). Lamp-hq: A large-scale multi-pose high-quality database and benchmark for nir-vis face recognition. *International Journal of Computer Vision*, 129(5), 1467–1483.
- Yu, C., & Pei, H. (2021). Face recognition framework based on effective computing and adversarial neural network and its implementation in machine vision for social robots. *Computers & Electrical Engineering*, 92, 107128.
- Yu, L., Li, K., & Zheng, J. (2021). Analysis of the Influence of Illumination Change on Face Recognition. *International Conference on Intelligent Automation and Soft Computing*, 430–435.
- Zainuddin, Z., & Laswi, A. S. (2017). Implementation of the LDA algorithm for online validation Based on face recognition. *Journal of Physics: Conference Series*, 801(1), 12047.
- Zeng, D., Veldhuis, R., & Spreeuwers, L. (2021). A survey of face recognition techniques under occlusion. *IET Biometrics*, 10(6), 581–606.
- Zeng, D., Veldhuis, R., Spreeuwers, L., & Arendsen, R. (2021). Occlusion-invariant face recognition using simultaneous segmentation. *Iet Biometrics*, 10(6), 679–691.
- Zeng, J., Zhao, X., Gan, J., Mai, C., Zhai, Y., & Wang, F. (2018). Deep convolutional neural network used in single sample per person face recognition.

Computational Intelligence and Neuroscience, 2018.

- Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks. *IEEE Signal Processing Letters*, 23(10), 1499–1503. <https://doi.org/10.1109/LSP.2016.2603342>
- Zhang, L., Li, C., Fan, X., & Mo, S. (2021). Multi-task and Multi-scale Face Recognition Based on CNN. *2021 IEEE 4th International Conference on Computer and Communication Engineering Technology (CCET)*, 85–90.
- Zhao, Q., & Ye, M. (2010). The application and implementation of face recognition in authentication system for distance education. *2010 International Conference on Networking and Digital Society*, 1, 487–489.
- Zheng, Z., Xu, B., Ju, J., Guo, Z., You, C., Lei, Q., & Zhang, Q. (2022). Circumferential Local Ternary Pattern: New and Efficient Feature Descriptors for Anti-counterfeiting Pattern Identification. *IEEE Transactions on Information Forensics and Security*, 1–1. <https://doi.org/10.1109/TIFS.2022.3154289>
- Zhou, L. (2021). Effect Evaluation and Influencing Factors of E-Learning Training in Colleges. *International Journal of Emerging Technologies in Learning (IJET)*, 16(22), 73–86. <https://doi.org/10.3991/ijet.v16i22.26877>
- Zhu, Y., Zhu, C., & Li, X. (2018). Improved principal component analysis and linear regression classification for face recognition. *Signal Processing*, 145, 175–182.