

BÖLGE TABANLI PARÇALI YÜZ TANIMA

Veli Yigit YOLCU

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EYLÜL 2013
ANKARA**

Veli Yiğit YOLCU tarafından hazırlanan “BÖLGE TABANLI PARÇALI YÜZ TANIMA” adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Hasan Şakir BİLGE

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy çokluğu ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Prof. Dr. Şeref SAĞIROĞLU

Bilgisayar Mühendisliği, Gazi Üniversitesi

Doç. Dr. Hasan Şakir BİLGE

Bilgisayar Mühendisliği, Gazi Üniversitesi

Doç. Dr. M. Fatih DEMİRCİ

Bilgisayar Mühendisliği, TOBB Ekonomi ve Teknoloji Üniversitesi

Tez Savunma Tarihi: 16/09/2013

Bu tez ile G.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onamıştır.

Prof. Dr. Şeref SAĞIROĞLU

Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki 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 bildiririm.

Veli Yiğit YOLCU

BÖLGE TABANLI PARÇALI YÜZ TANIMA**(Yüksek Lisans Tezi)****Veli Yiğit YOLCU****GAZİ ÜNİVERSİTESİ****FEN BİLİMLERİ ENSTİTÜSÜ****Eylül 2013****ÖZET**

Klasik yüz tanıma algoritmaları yüz üzerinde bulunabilecek güneş gözlüğü, peçe vb. kapanmalarda başarılı olamamaktadır. Bu amaçla literatürde genellikle kapanmaların tespit edilip kapanma olmayan bölümler üzerinde tanıma yapan çalışmalar çokça yer almaktadır. Bu çalışmaların bazılarında yeteri kadar yüksek başarı oranına ulaşılamamış, bazılarında ise renkler kullanılarak kapanmalar tespit edilmeye çalışılmıştır. Renk bilgisi kullanan çalışmaların pratikte geçerlilikleri düşüktür, çünkü kapanmalar her türlü şekilde ve çok çeşitli renklerde oluşabilmektedir. Ayrıca kapanmaların tespiti işlem maliyetini artırmaktadır. Son zamanlarda doğrusal yakınsama yöntemleri kapanma problemlerinde kullanılarak başarılı sonuçlar elde edilmiştir. Bu çalışmada geliştirilen algoritma, iki aşamalı bir yapıya sahiptir; birinci aşamada kNN sınıflandırıcısı (k-Nearest Neighbor, k-En yakın komşuluk) ve ikinci aşamada LR (Linear regression, Doğrusal regresyon) sınıflandırıcısı uygulanmaktadır. Bu yaklaşımda hem yerel öznitelikler hem de genel öznitelikler kullanılmaktadır. Öznitelik çıkarımı, öklit haritası ile görüntü üzerindeki değişim bilgisi kullanılarak gerçekleştirilmektedir. Öklit haritasında, her nokta için pikselin komşu piksellerine olan öklit uzaklığı hesaplanmaktadır. Öklit haritası kullanıldığında istenmeyen değişimler görüntüden atılabilmekte ve tanıma işleminde kullanılacak değişim aralığı belirlenebilmektedir.

Deneysel çalışmalarda AR veri tabanı kullanılarak yüz tanıma işlemi yapılmıştır. Deneylerde 2 türlü eğitim kümesi kullanılmıştır; birincisinde her bir kişi için tek eğitim görüntüsü bulunmaktadır, ikincisinde her bir kişi için birden fazla eğitim görüntüsü bulunmaktadır. Test için ise eğitim kümesinde yer alan kişilerin gözlüklü ve peçeli görüntüleri kullanılmıştır. Yapılan deneylerde her bir kişi için tek eğitim görüntüsünün kullanıldığı durumda gözlük kapanmasında %98 ve peçe kapanmasında %96 yüz tanıma başarı oranları elde edilmiştir. Her bir kişi için birden fazla eğitim görüntüsünün kullanıldığı durumda gözlük kapanmasında %100 ve peçe kapanmasında %98 yüz tanıma başarı oranları elde edilmiştir. Deneysel sonuçlar, geliştirilen algoritmanın başarılı olduğunu göstermiştir.

Bilim Kodu : 902.1.067

Anahtar Kelimeler : Yüz tanıma, kNN, doğrusal regresyon, kapanma (örtme)

Sayfa Adeti : 60

Tez Yöneticisi : Doç. Dr. Hasan Şakir BİLGE

REGION BASED PARTIAL FACE RECOGNITION**(M.Sc. Thesis)****Veli Yigit YOLCU****GAZİ UNIVERSITY****GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES****September 2013****ABSTRACT**

If faces are under occlusions like sunglasses, scarfs etc., classical face recognition algorithms could not succeed in recognition task. For this purpose, there are a lot of studies in the literature which firstly determine occlusions on faces and then perform recognition task on unoccluded parts. In some of these studies, satisfactory success rates haven't been achieved; in some of others, colors have been used for determining occlusion. Studies which are using color information are not acceptable enough for real life applications, because occlusions can be in any form with various colors. Furthermore, the step of determining occlusions boosts computation cost. Recently, successful results are achieved by applying linear convergence techniques on occlusion problems. In this study, an approach with a two-step architecture is proposed; in the first step kNN (k-Nearest neighbor) classifier is used and in the second step LR (Linear regression) classifier is used. In this approach, both local and holistic features are utilized. Feature extraction is applied by using Euclidean map where variation information on the image is utilized. In Euclidean map, pixel's euclidean distance to its neighboring pixels are calculated for each point. By using such a technique, unnecessary variations can be thrown out and variation range that is used in recognition task can be specified.

In this study, AR database was used in experiments for face recognition. In experiments, two kinds of training set are used; the first one includes single

image per subject and the second one includes multiple images per subject. For testing, images that include sunglasses and scarf of the same subjects are used. For multiple training samples per subject case, 100% face recognition success rate in sunglasses occlusion experiments and 98% face recognition success rate in scarf occlusion experiments were achieved. In single training sample per subject case, 98% face recognition success rate in sunglasses occlusion experiments and 96% face recognition success rate in scarf occlusion experiments were achieved.

Science Code : 902.1.067
Key Words : Face recognition, kNN, linear regression, occlusion
Page Number : 60
Supervisor : Assoc. Prof. Dr. Hasan Şakir BİLGE

TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren Hocam Doç.
Dr. Hasan Őakir BİLGE'ye teőekkürü bir borç bilirim.

İÇİNDEKİLER**Sayfa**

ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ÇİZELGELERİN LİSTESİ.....	xi
ŞEKİLLERİN LİSTESİ	xii
1. GİRİŞ	1
2. YÜZ TANIMA	5
2.1. Yüz Tanıma Sistemleri	5
2.2. Yüz Tanıma Sistemlerindeki Zorluklar	6
2.2.1. Yüzden elde edilecek öznelikleri etkileyen faktörler.....	6
2.2.2. Öznelik boyutu	9
2.2.3. Örnek sayısı problemi.....	9
2.3. Yüz Tanıma Sistemlerinde Kullanılan Bazı Teknikler	10
2.3.1. Alt uzay yöntemleri	10
2.3.2. Yapay sinir ağları	10
2.3.3. Dalgacık yöntemleri.....	11
2.3.4. Diğer yöntemler.....	11
2.4. Doğrusal Yakınsama Yöntemleri	12
2.4.1. Aşırı tanımlanmış sistemler (Overdetermined systems).....	12
2.4.2. Eksik tanımlanmış sistemler (Underdetermined systems).....	13

Sayfa

2.5. Yerel Yüz Tanıma Sistemleri	15
3. LİTERATÜRDEKİ ÇALIŞMALAR	17
4. GELİŞTİRİLEN YÖNTEM	27
4.1. Yöntemin Çalışma Şekli	27
4.2. Sınıflandırma	28
4.3. kNN (k – Nearest Neighbour, k-En Yakın Komşu) Sınıflandırıcısı	28
4.4. LRP (Linear Regression Predictor) Sınıflandırıcısı	30
4.5. Öznitelik Çıkarımı ve Seçimi	30
5. DENEYSEL ÇALIŞMALAR	35
5.1. AR Veri tabanı	35
5.2. Öklit Haritasında Kullanılacak Alt Sınırın Bulunması	37
5.3. En iyi Alt Örnekleme Miktarının Belirlenmesi	41
5.3.1. Küçük eğitim kümesi kullanılarak elde edilen sonuçlar	41
5.3.2. Büyük eğitim kümesi kullanılarak elde edilen sonuçlar	43
5.3.3. Doğrusal yakınsama tabanlı çalışmalarla benzer deneyler yapılarak elde edilen sonuçlar	44
5.4. Frekans Değerinin Etkinliğinin İncelenmesi	46
5.5. Sonuçların Literatür İçi Diğer Çalışmalarla Karşılaştırılması	47
6. SONUÇLAR VE ÖNERİLER	50
KAYNAKLAR	52
ÖZGEÇMİŞ	60

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Literatürde kapanma problemini kapsayan çalışmalar	3
Çizelge 5.1. 90x90 alt örneklemede öklit sınırlarının başarıya etkisi	39
Çizelge 5.2. 45x45 alt örneklemede öklit sınırlarının başarıya etkisi	40
Çizelge 5.3. Küçük veri setinde farklı alt örnekleme göre elde edilmiş başarı oranları (%) (İlk oturum)	42
Çizelge 5.4. Küçük veri setinde farklı alt örnekleme göre elde edilmiş başarı oranları (%) (İkinci oturum)	43
Çizelge 5.5. Büyük eğitim kümesi kullanılarak elde edilen sonuçlar	44
Çizelge 5.6. Yüz ifadesi değişimi problemine karşı dayanıklılığın incelenmesi için yapılan deneyden elde edilen başarı oranları	45
Çizelge 5.7. Geliştirilen yöntemin farklı oturumlar üzerinde denenmesi ile elde edilen başarı oranları (%)	46
Çizelge 5.8. İlk sınıflandırıcı güvenilirliği artırılarak yapılan deney sonucunda elde edilen başarı oranları (%)	46
Çizelge 5.9. Her kişi için tek eğitim görüntüsü kullanan çalışmaların başarı oranları (%)	48
Çizelge 5.10. Doğrusal yakınsama tabanlı çalışmaların başarı oranları (%)	49

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Genel örüntü tanıma sistemleri	5
Şekil 2.2. Poz farklılıklarından kaynaklanan bozulmalar	7
Şekil 2.3. Işıklandırma etkisine maruz kalmış görüntü.....	8
Şekil 2.4. Yüz ifadesi değişimleri	9
Şekil 2.5. Yerel yüz tanıma sistemleri	15
Şekil 3.1. a) PCA, b) ICA, c) ICA mimarisi II, d) LS-ICA, e) LNMF, f) LFA.....	20
Şekil 3.2. Kapanma içeren görüntüler ve onarılmış halleri.....	22
Şekil 3.3. Tamamlanmamış öznitelik noktası p3 ve farklı düzlemler.....	24
Şekil 4.1. Öklit haritasının parçalanması	27
Şekil 4.2. Sistemin blok diyagramı	28
Şekil 4.3. kNN sınıflandırıcısının çalışma şekli.....	29
Şekil 4.4. Türkiye 2002 seçim haritası.....	31
Şekil 4.5. Öklit haritasının elde edilmesi	33
Şekil 4.6. Değişimlerin çoğunluğunun yansıtılması	33
Şekil 4.7. WLD ile elde edilmiş görüntüler	34
Şekil 5.1. AR veri tabanında yer alan yüz görüntüleri.....	37
Şekil 5.2. Geniş alt örnekleme aralığına göre elde edilmiş alt sınır ve ortalama başarı oranı grafiği	38
Şekil 5.3. Seçilen değişim aralığı kullanılarak elde edilen öklit haritası	40
Şekil 5.4. Frekans değerinin etkinliği	47

SİMGE VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ANN	Artificial Neural Networks Yapay Sinir Ağları
AR	Alex Martinez ve Robert Benavente
BBOW	Block-based Bag of Words Parça Tabanlı Kelime Çantası
BMU	Best Matching Unit En İyi Eşleşen Birim
BOW	Bag of Words Kelime Çantası
CPCA	Component based PCA Bileşen Tabanlı PCA
CVX	Disciplined Convex Programming Disiplinli Konveks Programlama
DCT	Discrete Cosine Transform Ayrık Kosinüs Dönüşümü
FFT	Fast Fourier Transform Hızlı Fourier Dönüşümü
HE	Histogram Equalization Histogram Eşitlemesi
HMF	Hidden Markov Field Gizli Markov Alanı
HMM	Hidden Markov Model Gizli Markov Modeli
ICA	Independent Component Analysis Bağımsız Bileşen Analizi

Kısaltmalar	Açıklama
IFS	Iterated Function System İteratif Fonksiyonel Sistem
kNN	k-Nearest Neighbor k-En Yakın Komşuluk
KLD	Kullback-Leibler Divergence Kullback-Leibler Farklılığı
LASSO	Least Absolute Shrinkage and Selection Operator En Küçük Mutlak Büzülme ve Seçim Operatörü
LBP	Local Binary Patterns Yerel İkili Örüntüler
LDA	Linear Discriminant Analysis Doğrusal Ayırıştırma Analizi
LFA	Local Feature Analysis Yerel Öznitelik Analizi
LGBP	Local Gabor Binary Pattern Yerel Gabor İkili Örüntüsü
LHE	Local Histogram Equalization Yerel Histogram Eşitlemesi
LNMF	Local non-Negative Matrix Factorization Yerel Negatif Olmayan Matris Ayırıştırması
LPCA	Lophoscopic PCA
LR	Linear Regression Doğrusal Regresyon
LRP	Linear Regression Predictor Doğrusal Regresyon Belirleyicisi
LS_ICA	Locally Salient ICA Yerel Olarak Belirgin ICA
NN	Nearest Neighbour En Yakın Komşuluk

Kısaltmalar	Açıklama
NS	Nearest Subspace En Yakın Alt Uzay
NTSC	National Television System Committee Ulusal Televizyon Sistemi Komitesi
PAL	Phase Alternating Line Faz Değişirici Hat
PALM	Primal Augmented Lagrange Multiplier İlkel Genişletilmiş Lagrange Çarpanı
PCA	Principal Component Analysis Temel Bileşen Analizi
RGB	Red, Green, Blue Kırmızı, Yeşil, Mavi
ROI	Region of Interest İlgi Alanı
RSM	Random Subspace Method Rastgele Altuzay Metodu
SR	Sparse Representation Seyrek Temsil
SRC	Sparse Representation Classification Seyrek Temsil Yaklaşımı Tabanlı Sınıflandırma
SIFT	Scale Invariant Feature Transform Ölçekten Bağımsız Öznitelik Dönüşümü
SOM	Self Organizing Maps Kendinden Düzenlenen Haritalar
SVD	Singular Value Decomposition Tekil Değer Ayrışımı
SVM	Support Vector Machine Destek Vektör Makinesi

Kısaltmalar**Açıklama****WLD**

Weber Local Descriptor

Weber Yerel Tanımlayıcısı

Simgeler**Açıklama****E**

İfade etkisi

I

Işık etkisi

O

Kapanma etkisi

y

Test vektörü

x

Katsayılar vektörü

M

Orijinal görüntü

X

Öklit haritası

f

Komşuluk seçme fonksiyonu

A

Eğitim vektörlerini içeren matris

 γ

Düzenleyici parametre

 δ

Katsayı seçen fonksiyon

m

Öznelik boyutu

n

Eğitim sayısı

h

Görüntünün yüksekliği

w

Görüntünün genişliği

v

Komşuluk vektörü

c

Merkez vektörü

k

Merkez ve komşuluk vektörü boyutu

a

Eğitim vektörleri katsayıları

v

Eğitim vektörleri

 \hat{x}_1

Optimizasyon sonucunda oluşmuş katsayılar vektörü

 x_0

Görüntü katsayı vektörü

 e_0

Kapanma katsayı vektörü

 ϵ

Hata parametresi

1. GİRİŞ

Hızla gelişen teknoloji ile aynı doğrultuda ihtiyaçlar ve beklentiler de artmaktadır. Gelişen ve değişen ihtiyaçlar ile birlikte toplum refahını yakından ilgilendiren güvenlik sistemlerinin yenilenmesi ve geliştirilmesi ihtiyacı doğmaktadır. Bu amaçla geliştirilen biyometri tabanlı sistemler bankacılık, adalet işleri, asayiş ve istihbarat gibi alanlarda büyük önem taşımaktadır. Biyometrik sistemler yüz, parmak izi, el izi, iris, retina, imza, ses gibi birçok kişilerin ayırt edici biyometrik özelliklerini kullanarak kişilerin doğrulanmasını veya tanınmasını sağlayan sistemlerdir.

Yüz tanıma sistemleri kişilerin yüz bilgilerini kullanarak tanıma yapan sistemlerdir. Bu sistemler suçluların teşhisinde güvenlik güçleri tarafından özellikle hava alanları ve gümrük kapıları gibi önemli geçiş yerlerinde kullanılabilir. Yüz tanıma sistemlerinin kişilerin sokaklara yerleştirilen kameralar ile izlenmesi ve takip edilebilmesi gibi nedenlerden dolayı özel hayatın gizliliğini ilgilendiren yönleri de vardır.

Geleneksel yüz tanıma metotları yüzü bütün olarak değerlendirmekte ve bu durum tanıma işleminin kapanmalar ve ifade değişiklikleri gibi deformasyonlara karşı başarısız olmasına neden olmaktadır. Teorik olarak bütüncül metotlar başarılı olsa da gerçek hayatta yüzlerde birçok bozulma meydana gelmektedir. Örneğin bir yüzde gözlük olması, peçe olması veya çekim sırasında bir nesne tarafından bir kısmının kapanması muhtemeldir. Bu ve buna benzer problemler bütüncül metotların başarısını büyük oranda düşürmektedir [1]. Bu gibi durumlara karşı son 10 yılda yapılan çalışmalarda daha önce bütüncül olarak uygulanan metotların yerel olarak uygulanmasıyla bu probleme çözüm aranmıştır. Bu amaçla en çok tercih edilen yöntemler yerel yöntemlerdir. Yerel metotlar yüzü parçalara ayırıp yerel öznitelikler üzerinde çalışmaktadır.

Boyut indirgeme ve öznitelik çıkarımı gibi amaçlarla sıklıkla kullanılan PCA (Principal Component Analysis), LDA (Linear Discriminant Analysis) ve SVD (Singular Value Decomposition) vb. alt uzay teknikleri geçtiğimiz 10 senede

kapanma problemlerinin çözümünde sıklıkla kullanılmıştır [2-16]. Doğrusal olmayan problem çözümlerinde kullanılan ve ses tanıma, el yazısı tanıma vb. birçok alanda uygulaması olan yapay sinir ağları kapanma olan yüz tanıma problemlerine uygulanarak başarılı sonuçlar elde edilmiştir [17-23]. Bunların yanı sıra yine geleneksel yöntemlerde sıklıkla kullanılan dalgacık yöntemlerine kapanma problemlerinin çözümünde sıklıkla başvurulmuştur [24-34]. Doğrusal yakınsama temelli tekniklerin kapanmalarda iyi sonuçlar verdiği çeşitli çalışmalarda gösterilmiştir [35-46]. Bu çalışmalarda eğitim görüntüleriyle test görüntüleri arasında doğrusal bir ilgi kurularak tanıma yapılmaktadır. Doğrusal yakınsama teknikleri son zamanlarda tercih edilen popüler yaklaşımlardandır. HMM (Hidden Markov Model), HMF (Hidden Markov Field) ve Gauss modellemeleri vb. istatistiksel yaklaşımlar da literatürde kullanılmıştır [47-56]. Bu gibi çalışmalarda kapanmalar HMM veya bayes ağı gibi yöntemlerle modellenip kapanma durumunda başarı oranı artırılabilir. IFS (Iterated Function System) teorisi tabanlı çalışmalar da daha önce sayılanlardan biraz daha farklı bir çalışma alanı olarak göze çarpmaktadır [57-59]. Genellikle nesne tanıma problemlerinde kullanılan ve başarılı sonuçlar üreten SIFT (Scale Invariant Feature Transform) tekniğini bu alanda da uygulayan çalışmalarda başarılı sonuçlar elde edilmiştir [60-62]. Bunların yanında katarlar [63], graf modellemeleri [64], momentum teknikleri [65], kodlama teknikleri (Hashing) [66] ve görüntü tabanlı yöntemler [67] bu alanda kullanılan diğer yöntemlerdir. Buraya kadar bahsedilen 2 boyutlu yöntemlerin yanı sıra 3 boyutlu yöntemler de geliştirilmiştir [68-73].

Literatürde kapanma problemi için birçok çözüm yöntemi geliştirilse de bunların bazıları tatmin edici başarı oranlarına ulaşamamıştır. Kapanmaların tespit edilip temiz kısımlarda tanıma yapan sistemlerde başarılı sonuçlar elde edilebilmektedir. Kapanmaların tespitinde kapanmaların önceden varlığının bilindiği varsayılan çalışmalarda yüksek sonuçlar elde edilebilmesine rağmen böyle bir durumun pratikte uygulanabilirliği zordur. Ten renginin kullanılmasıyla kapanmaların tespit edildiği çalışmalarda güneş gözlüğü vb. siyah kapanmaları içeren veri tabanlarında iyi sonuçlar elde edilmesine rağmen bir önceki yaklaşımla paralel olarak yine bu

durumun pratikte uygulanabilirliđi zordur. Bunun en temel sebebi kapanmaların deđişen büyüklüklerde ve renklerde olmak üzere geniş bir çeşitliliđe sahip olmasıdır.

Çizelge 1.1’de literatürdeki çalışmalar uygulanan yöntemlere göre gruplar halinde verilmiştir.

Çizelge 1.1. Literatürde kapanma problemini kapsayan çalışmalar

Uygulanan Yöntem	Kaynak Numarası
Alt uzay teknikleri	2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16
Yapay sinir ađları	17, 18, 19, 20, 21, 22, 23
Dalgacık yöntemleri	24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34
Dođrusal yakınsama yöntemleri	35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46
İstatistiksel yöntemler	47, 48, 49, 50, 51, 52, 53, 54, 55, 56
IFS	57, 58, 59
SIFT	60, 61, 62
Diđer yöntemler	63, 64, 65, 66, 67
3 Boyutlu çalışmalar	68, 69, 70, 71, 72, 73

Tez çalışmasında komşuluk seçimi ve sınıflandırmaya katkı sağlaması açısından bir NN (Nearest Neighbour, En Yakın Komşu) sınıflandırıcısı ile son zamanlarda popüler olarak kullanılan ve kapanmalarda dayanıklılıđı çeşitli çalışmalarda gösterilmiş olan doğrusal yakınsama tekniđi kullanılmıştır. Sistem hem parçalı hem de bütüncül çalıştığı için hibrit yapıdadır. Kapanmalarda bütüncül bir algoritmanın komşuluk seçimi başarısı düşeceğinden dolayı ilk sınıflandırıcı parçalı olarak çalıştırılarak komşuluk seçimi işlemi sağlamlaştırılmıştır. Doğrusal yakınsama sınıflandırıcıları bütüncül olarak da kapanmalara karşı dayaknıklı olduğundan ve parçalı tekniklerde parçalar arası kaybolan korelasyonun da değerlendirilmesi amacıyla bütüncül olarak çalıştırılmaktadır. Ayrıca kapanmaların aşırı etkisinin giderilmesi amacıyla bir deđişim haritası elde edilmekte ve bu harita üzerinde aşırı deđerler atılarak başarı oranının yükseltilmesi amaçlanmıştır.


Bu alıřmada 2. Blmde yz tanıma sistemlerinden bahsedilmiř, 3. Blmde literatrde kapanma problemine zm olarak geliřtirilmiř tekniklerden bahsedilmiř ve 4. Blmde ise geliřtirilen sistem anlatılmıřtır. 5. Blmde deneysel alıřmaların sonuları verilmiřtir. 6.Blmde sonu ve neriler zetlenmiřtir.

2. YÜZ TANIMA

2.1. Yüz Tanıma Sistemleri

Yüz tanıma sistemleri, el yazısı tanıma sistemleri, plaka tanıma sistemleri ve ses tanıma sistemleri gibi birçok sistem örüntü tanıma sistemi olarak tanımlanır. Örüntü tanıma sistemleri, nesnelerin ayırt edici özelliklerini kullanarak tanıma yapan sistemlerdir.

Örüntü tanıma sistemlerinde genel olarak veri ön işleme, öznitelik çıkarımı, öznitelik seçimi ve sınıflandırma olmak üzere 4 aşama vardır (Şekil 2.1).



Şekil 2.1. Genel örüntü tanıma sistemleri

Örnek olarak ön işleme adımı yüzlerin temizlenmesi, histogram eşitlemesi kullanılarak ışıktan kaynaklanan sapmaların indirgenmesi, yüzlerin standart ve doğru konumlandırılması gibi işlemleri içerir. Öznitelik çıkarımı aşamasında PCA [74], ICA (Independent Component Analysis) [75] ve LDA [76] gibi alt uzay teknikleri [77], FFT (Fast Fourier Transform) ve DCT (Discrete Cosine Transform) [51] gibi dalgacık teknikleri, SOM (Self Organizing Map) [21,22] gibi yapay sinir ağları teknikleri kullanılabilir. Her bir tekniğin uygulama alanı farklı olabilmekte ve uygulandıkları alana göre artıları ve eksileri olabilmektedir. Öznitelik seçimi aşamasında ise ayırt ediciliği bozan veya gereksiz öznitelikler tespit edilerek kullanım dışı bırakılır. Bu aşamaya örnek olarak PCA uygulanırken en yüksek öz değere sahip belirli bir sayıda öz vektörün seçilmesi gösterilebilir. Sınıflandırma aşamasında ise Bayes sınıflandırıcısı, kNN (k-nearest neighbor) sınıflandırıcısı, SR

(Sparse Representation) sınıflandırıcısı ve SVM (Support Vector Machine) [32,45,60] vb. sınıflandırıcılar kullanılabilir.


2.2. Yüz Tanıma Sistemlerindeki Zorluklar

2.2.1. Yüzden elde edilecek öznitelikleri etkileyen faktörler

Gerçek hayatta yüz üzerinde zaman faktöründen, duruştan (poz değişiklikleri), ışıklandırmadan, kapanmalardan ve yüz ifadesinden kaynaklanan birçok etki söz konusu olmaktadır.

Duruş bozuklukları öznitelik yapılarında uyumsuzluklara neden olabilmekte ve tanıma işlemini imkânsız kılabilir. Örneğin düz bir yüz görüntüsünde yer alan bir piksel ile aynı görüntünün belirli bir açı ile yatırıldığı görüntüdeki aynı piksel aynı değeri içermez. Duruş bozuklukları yüz üzerinde sağa sola veya öne arkaya yatma gibi doğal nedenlerden kaynaklanabileceği gibi fotoğraf çekimi esnasında meydana gelen hatalardan da kaynaklanabilmektedir [47].

Şekil 2.2’de aynı görüntünün öne eğimli yüzden elde edilmesiyle düzgün bir yüzden elde edilmesi arasındaki fark gösterilmektedir. Şekilden de görülebileceği gibi göz, burun ve ağız gibi bölgelerde kaymalar olmaktadır ve bu durum tanıma performansını düşürecektir.



Şekil 2.2. Poz farklılıklarından kaynaklanan bozulmalar [47]

Aynı kişinin iki farklı görüntüsünün birinde kişinin yüzü diğerine göre öne doğru daha fazla eğilidir. Bu durum iki görüntü arasında göz hizalarının bozulmasına neden olmuştur.

Işıklandırma etkisi yüz özniteliklerini bozan ayrı bir etmendir. Işıklandırma yüz üzerindeki piksel değerlerini değişmesine neden olur. Işıklandırma yüzün bir kısmını etkileyebilirken, tamamına da etki edebilmektedir. Bu gibi etkileri azaltmak için HE (Histogram Equalization) veya LHE (Local Histogram Equalization) gibi yöntemler kullanılabilir [78]. Literatürde yer alan çalışmalarda HE ön işleme aşamasında tercih edilen bir yöntemdir.

Şekil 2.3'de görüldüğü üzere görüntü aşırı derecede ışığa maruz kalmış ve bu olay görüntü üzerindeki sakal, burun ayrıntıları gibi bazı ayrıntıların fark edilmesini zor hale getirmiştir.



Şekil 2.3. Işıklandırma etkisine maruz kalmış görüntü
a) Işıklandırma etkisine maruz kalmamış görüntü, b) Tüm yüzü etkileyen
ışıklandırma etkisine maruz kalmış görüntü

Yüz tanıma sistemlerinde karşılaşılan diğer bir problem ise yüz ifadeleridir. Yüz ifadeleri türüne göre yüz üzerinde değişik bölgeleri değişik şiddetlerde etkileyebilmektedir. Örneğin bağırmaya ifadesi yüzün genelini etkilerken gülümseme ağız bölgesini ve göz bölgesini kişiden kişiye değişecek şekilde etkileyebilmektedir. Literatürde yüz ifadelerinin tanınmasını sağlayan metotlar mevcuttur ve yüz ifadesinin meydana getirdiği değişikliğe göre yüz üzerinde ağırlıklandırma yapmak bir çözüm yöntemi olarak uygulanabilmektedir [47].

Şekil 2.4'te görüldüğü üzere bağırmaya ifadesi yüz üzerinde hemen hemen her bölgede değişime sebep olmuştur. Özellikle ayırt ediciliğin yüksek olduğu göz ve ağız bölgesi büyük ölçüde değişime uğramış, bu nedenle bu gibi sebepler nedeniyle meydana gelebilecek değişimlerde görüntüler üzerinde tanıma yapmak oldukça güç hale gelebilmektedir.



Şekil 2.4. Yüz ifadesi değişimleri

a) İfade değişimi olmayan görüntü, b) Bağırma ifadesi olan görüntü

Zaman faktörünün yüzler üzerinde meydana getirdiği değişimler yüz tanıma sistemleri için en büyük problemlerden biridir. Belirli bir zaman dilimi içerisinde kilo değişimlerine veya yaşlanmaya bağlı olarak yüzde değişimler meydana gelebilmektedir. Bu gibi durumlar eğitim için kullanılan görüntü ile test görüntüsü arasındaki benzerliği büyük ölçüde olumsuz etkileyebilmektedir.

2.2.2. Öznitelik boyutu

Yüz görüntüleri doğal haliyle çok büyük öznitelik boyutlarına sahip olmaktadır. Örneğin 120x165 boyutlarındaki görüntü vektörize edildiğinde 19800 boyutunda bir vektör elde edilir. Bu sayılar üzerinde işlem yapılırken algoritma karmaşıklığı düşünüldüğünde işlem maliyeti artmaktadır. Bu problemler PCA vb. tekniklerle veya alt örnekleme teknikleriyle aşılabilmektedir.

2.2.3. Örnek sayısı problemi

Gerçek hayatta tasarlanacak sistemlerde her bir kişi için çeşitli ve çokça görüntü elde edilmesi çok zor bir durumdur. Fakat bir yüz tanıma sisteminin en iyi şekilde eğitilebilmesi için her bir sınıf için öznitelik uzay boyutunun en az 10 katı kadar

eđitim grnts kullanılmalıdır [47]. Bu yzden yz tanıma sistemlerinde znelik sayısının eđitim rneklerinin sayısına gre dřk tutulması beklenmektedir.

2.3. Yz Tanıma Sistemlerinde Kullanılan Bazı Teknikler

2.3.1. Alt uzay yntemleri

Yz tanıma problemi yzn dođrusal olmama zelliđinden dolayı zlmesi en g problemlerden biridir. Yz verilerindeki znelik boyutlarının ok byk deđerlere ulařmasından dolayı znelik uzayının olabildiđince az kayıpla daha az boyuttaki bařka bir uzaya haritalanması ihtiyacı dođmuřtur. Bu amala ilk geliřtirilen teknik PCA'dır. PCA iřleminde tm yzlerin ortalaması hesaplanarak bir ortalama yz elde edilir. Bu yz diđer tm yzlerden ıkarılarak veriler uzayda merkezileřtirilir. Daha sonra kovaryans matrisi hesaplanır ve en yksek z deđerlere karřılık gelen z yzler seilerek dnřm matrisi elde edilir. Daha sonra tm yzler bu dnřm matrisi kullanılarak yeni uzaya haritalanır.

PCA'dan sonraki ařamada LDA geliřtirilmiřtir. LDA'yı PCA'dan ayıran zelliđi sınıflar arasındaki farklılıđı maksimize etmeye, sınıf ii farklılıđı minimize etmeye alıřmasından kaynaklanır.

Bu metotların yanı sıra ICA, PCA'nın genelleřtirilmiř hali gibi dřnlse de ICA'da temel grntlerin ortogonal olması gerekmez ve bu yeniden oluřturma hatasını indirger [79]. Ayrıca ICA ile grntler daha iyi karakterize olur. ICA ayırt edici zellikleri bulurken sadece kovaryans matrisinden deđil, yksek derece istatistiksel yntemlerden de faydalanır [79].

2.3.2. Yapay sinir ađları

Yapay sinir ađları insan beyninin sinir hcrelerinin bilgisayar ortamında taklit edilmesidir. Yapay sinir ađları dođrusal olmayan problem zmlerinde sıklıkla kullanılan tekniklerdendir. Bu zelliđiyle rnt tanıma problemlerinde de

kullanılabilmektedir. Fakat yüz özniteliklerinin büyük boyutlu olmasından dolayı yüz tanıma sistemlerine uygulanmadan önce genellikle boyut indirilmesi yapılır.

Yapay sinir ağları problemlere göre değişik topolojilerde hazırlanabilmektedir. Klasik yapay sinir ağları topolojilerinin yanı sıra ilişkisel bellek mantığını gerçekleyen SOM tekniği bu alandaki popüler tekniklerden biridir.

2.3.3. Dalgacık yöntemleri

FFT (Fast Fourier Transform), Gabor dalgacık dönüşümü, Gabor filtresi ve ayrık kosinüs dönüşümü bu alanda en çok kullanılan yöntemlerdendir. Gabor filtresi uzaysal lokalizasyon, uzaysal frekans ve yönelim seçimi gibi çeşitli öznitelikleri ortaya çıkarabildiği için örüntü tanıma problemlerinde kullanılacak en güçlü araçlardan biridir [79]. Gabor filtrelerinin ışıklandırma ve poz problemlerine dayanıklı olduğu bilinmektedir.

DCT'de sonlu sayıdaki veri noktaları farklı frekans değerlerine sahip kosinüs fonksiyonlarının toplamı şeklinde ifade edilir. DCT Fourier dönüşümü ile yakın ilişkilidir fakat sadece gerçek sayıları kullanır. Yüz görüntülerinde enerji daha düşük frekanslarda bulunur.

2.3.4. Diğer yöntemler

Bayes ağları, HMM gibi tekniklerle yüz veya kapanmalar modellenabilmektedir. HMM Bayes ağlarına benzerdir, fakat HMM içinde durumlar gizlidir ve sadece geçiş ve çıkış durumları bilinmektedir. Gizli durumlar Viterbi algoritması ile tahmin edilebilmektedir.

IFS merkezli yöntemler kullanılarak da kapanma durumlarına dayanıklılık sağlanabilmektedir. Bu yöntemde tüm görüntü için iç benzerlik haritası oluşturulur ve küçük kare alanlar içinde uygunluk araması yapılır [57].

2.4. Doğrusal Yakınsama Yöntemleri

Doğrusal yakınsama yöntemlerinin yüz tanıma sistemlerine dayanıklılık kazandırmasından dolayı araştırmacılar arasında popüler hale gelmiştir. Doğrusal sistemlerin çözümü için geçerli yöntemler sistemin tanımlanma durumuna göre değişmektedir. $A \in R^{m \times n}$ bir matris olmak üzere m vektör boyutunu ve n eğitim sayısını belirtmek üzere matrisin sütunları eğitim görüntülerinden oluşmaktadır. $y \in R^{m \times 1}$ test görüntüsünü, $x \in R^{n \times 1}$ katsayılar vektörünü belirtmektedir. Bu durumda Eş. 2.1 doğrusal eşitliği tanımlanabilmektedir.

$$y = Ax \quad (2.1)$$

Yukarıdaki eşitlikte y test vektörü A matrisi içinde yer alan vektörlerin doğrusal bileşimi olarak ifade edilmektedir. Yani $x = [a_1, a_2, \dots, a_n]^T$ ve $A = [v_1, v_2, \dots, v_n]$ olmak üzere a katsayıları v görüntü sütun vektörlerini belirtmektedir. Bu durumda $y = a_1 v_1 + a_2 v_2 + \dots + a_n v_n$ olarak doğrusal bir eşitlikle ifade edilebilmektedir.

2.4.1. Aşırı tanımlanmış sistemler (Overdetermined systems)

Denklem sayısının bilinmeyenlerden fazla olduğu sistemler aşırı tanımlanmış sistemlerdir. Eş. 2.1 eğer aşırı tanımlanmış ise sistem en küçük kareler yöntemiyle çözülebilmektedir [46]. En küçük kareler yöntemi ile Eş. 2.1'nin çözümü Eş. 2.2 kullanılarak hesaplanabilir.

$$\hat{x}_1 = \operatorname{argmin}_x \|y - Ax\|_2^2 \quad (2.2)$$

Eş. 2.2'nin çözümü A matrisinin sözde tersi kullanılarak Eş. 2.3 ile elde edilebilmektedir [46].

$$x = (A^T A)^{-1} A^T y \quad (2.3)$$

y vektörünün sol tarafında yapılan işlem A matrisinin sol sözde tersidir (Eş. 2.4).

$$A^+ = (A^T A)^{-1} A^T \quad (2.4)$$

A^+ değeri matris çarpımları kullanılmadan SVD ile daha hızlı bir biçimde hesaplanabilmektedir.

$$\begin{aligned} A &= USV^T, S = \text{diag}(q_1, \dots, q_r, 0, \dots, 0) \\ A^+ &= VS^+U^T, S^+ = \text{diag}(q_1^{-1}, \dots, q_r^{-1}, 0, \dots, 0) \end{aligned} \quad (2.5)$$

Eş. 2.5 ile tanımlanan geri dönüşüm işlemi sırasında S^+ matrisi S matrisinin transpozununun alınıp elemanlarının tersinin alınmasıyla elde edilir.

2.4.2. Eksik tanımlanmış sistemler (Underdetermined systems)

Aşırı tanımlanmış sistemler için eşsiz bir çözüm elde edilebilirken eksik tanımlılar için aynı şey söz konusu değildir. Eksik tanımlı sistemlerin birden fazla çözümü olmaktadır. Bu sistemlerde ℓ_2 normu alınarak sistem çözülebilmeye rağmen yüz tanıma sistemlerinde elde edilen katsayılar yeterince bilgi verici olmamaktadır [35]. Bu yüzden ℓ_0 normu seyrek çözüm elde edebilmek için kullanılabilir, fakat ℓ_0 formunun hesaplanması NP-hard problem olup uygulanamaz [35]. Fakat ℓ_1 normu kullanılarak problem çözülebilir bir şekle dönüşmektedir [35]. Bu tekniğin yüz tanıma sistemlerinde kullanılmasıyla SRC (Sparse Representation Classification) [35] ortaya çıkmıştır.

SRC tekniği yüz tanıma sistemlerine başarıyla uygulanmış [35] ve yüz tanıma sistemlerine sağlamlık kazandırmıştır. SRC'de seyrek katsayılar Eş. 2.6 çözülerek elde edilebilir.

$$\hat{x}_1 = \text{minimize } \|x\|_1 \text{ subject to } y = Ax \quad (2.6)$$

Eş 2.6'daki az miktardaki gürültünün etkisinin giderilebilmesi için ε parametresi ile yeniden oluşturma hatası düzenlenebilir [35]. Bu durumda çözüm Eş. 2.7 ile elde edilebilir.

$$\hat{x}_1 = \text{minimize } \|x\|_1 \text{ subject to } \|Ax - y\|_2 \leq \varepsilon \quad (2.7)$$

Literatürde seyrek katsayıların elde edilmesi için birçok yöntem mevcuttur. Bunlardan düzenleyici parametre içeren ℓ_1 düzenlemeli en küçük kareler (ℓ_1 regularized least squares) versiyonu Eş. 2.8'de verildiği gibidir. Bu problem istatistik literatüründe Lasso (Least Absolute Shrinkage and Selection Operator) problemi olarak da bilinmektedir.

$$\hat{x}_1 = \text{argmin}_x \|y - Ax\|_2^2 + \gamma|x| \quad (2.8)$$

γ düzenleyici parametre olarak kullanılmıştır. İfadenin ilk kısmı yeniden oluşturma hatası, ikinci kısmı ise cezalandırıcı olarak kullanılmaktadır. İfadenin çözümünden elde edilecek x katsayıları seyrek ve test görüntüsünün en yakın olduğu eğitim görüntülerinin katsayılarının diğerlerine göre büyük olması beklenir.

Kapanma olaylarına dayanıklılık için Eş 2.6 genişletilebilmektedir. Kapanmaların da temel vektörlerin toplamı şeklinde ifade edilebileceği düşünüldüğünde Eş. 2.9'a dönüştürülebilmektedir [35].

$$y = [A, I] \begin{bmatrix} x_0 \\ e_0 \end{bmatrix} = Bw_0 \quad (2.9)$$

Yukarıdaki ifadede $B \in R^{m \times (n+m)}$ olmak üzere x_0 görüntü ve e_0 kapanma katsayılarını belirtmektedir. $\hat{w}_1 = [\hat{x}_1, \hat{e}_1]$ seyrek çözümü elde edildiğinde temiz görüntü $y_r = y - \hat{e}_1$ ile elde edilir [35]. Dolayısıyla tanıma işlemi bu katsayılar ve temiz görüntü ile Eş. 2.10 kullanılarak elde edilir [35].

$$r_i(y) = \|y_r - A\delta_i(\hat{x}_1)\|_2 = \|y - \hat{e}_1 - A\delta_i(\hat{x}_1)\|_2 \quad (2.10)$$

İfadede $\delta \times$ içinde yer alan i . sınıfa ait katsayıları seçen fonksiyondur.

SR ifadelerinin çözümü için konveks optimizasyon teknikleri kullanılabilir. Bu amaçla kullanılacak çeşitli çalışmalar ve yazılım paketleri mevcuttur. Interior–Point algoritması [80], CVX (Matlab Software for Disciplined Convex Programming) [81] veya Homotopy [82] ile bu ifade çözülebilmektedir. Ayrıca Lagrangian çarpanı kullanan PALM (Primal Augmented Lagrange Multiplier) [83] SR çözümlerinde diğerlerine göre daha verimli çalışabilmektedir. Bu algoritmalarla ilgili matlab yazılım paketleri sırasıyla [84], [81], [85], [86] adreslerinde mevcuttur.

2.5. Yerel Yüz Tanıma Sistemleri

Genel öznitelikleri kullanan klasik yüz tanıma sistemlerinin aksine, yerel yüz tanıma yerel öznitelikleri kullanan sistemlerdir. Yerel öznitelikler yüzün parçalara ayrılmasıyla elde edilir. Her bir parça ayrı ayrı işlenerek yüz tanıma işlemi gerçekleştirilir (Şekil 2.5).



Şekil 2.5. Yerel yüz tanıma sistemleri

Yerelleştirme ve birleştirme adımlarının uygulanma yeri uygulamadan uygulamaya değişebilmektedir. Birleştirme adımında kullanılan yöntem sistem tasarımına ve öznitelik yapısına göre değişiklik gösterebilir. Örneğin her bir parça için bir sınıf değeri atanmış ise en çok oy alan, her bir parça için benzerlik ifade eden bir değer atanmış ise en çok benzeyen veya ihtimal belirten bir değer atanmış ise en yüksek ihtimal ile eşleşen nesnenin sınıfı kullanılabilir.

Yerelleştirme parçalara bölünme mantığıyla tanımlanabilirken [47], uzaysal olarak da tanımlanabilmektedir [16]. Parçalara ayırma yönteminde yüz parçalara ayrılır ve

tanıma işleminde bu parçalardan elde edilen vektörler kullanılır. Parçalara ayırma yöntemindeki temel mantık kapanma olmayan bölgelerin bulunup kullanılmasına dayanır. Uzaysal yerleştirmede ise temel görüntüler üzerinde göz, burun ve ağız gibi ayırt ediciliği yüksek bölgeler vurgulanmaktadır. Ayrıca bu temel görüntüler üzerinde eleme yapılarak kapanmalara karşı dayanıklılık sağlanabilmektedir [2].

3. LİTERATÜRDEKİ ÇALIŞMALAR

Yüz tanıma problemlerinde yüzlerde bulunan gözlük, peçe gibi araçlardan dolayı kapanmalar ve ifade değişikliklerinden kaynaklanan nedenlerden dolayı yüz tanıma işlemi zorlaşmaktadır. Ayrıca yüzlerin lokalizasyonu da ayrı bir hata payına sahiptir. Martinez tarafından yapılan çalışmada bu problemleri çözmek için çok aşamalı bir yapı oluşturulmuştur. Lokalizyon probleminin çözümü için geliştirilen algorithmada öncelikle ön lokalizasyon için renkler kullanılmıştır. Renkler nesne sınıflandırmalarında ve yüz tanıma sistemlerinde ayırt edici bir öznelik olarak kullanılabilir, çünkü insan teninin kendine has bir renk aralığı bulunmaktadır. Bu işlem görüntüden yüzün ayırt edilebilmesi için kullanılmıştır. Ayrıca yüz üzerinde bulunan artık piksellerin temizlenmesi için genişleme ve daralma operatörleri kullanılmıştır. Daha sonra PCA tabanlı bir teknik kullanılarak ağız ve gözlerin yerleri bulunmuştur. Yüz bu koordinat değerleri kullanılarak, göz koordinatlarının yüksekliği eşit olana kadar çevrilmiştir. Son olarak yüzün kenar yatay ve dikey kısımları bulunarak 120x170 olacak şekilde yüz kesilmiştir. Gözleri veya ağızı kapalı yüzler için lokalizasyon diğer örneklerden elde edilen ortalama değerler üzerinden gerçekleştirilmiştir. Yeni bir yüzü tanımak için Mahalanobis uzaklığı kullanılmaktadır. Kapanma etkilerinin azaltılması için yüz birçok elips parçaya ayrılmıştır. Her parçanın PCA karşılığı hesaplandıktan sonra lokalizasyon hatası için her parça için ayrı ayrı Gauss modelleri hesaplanmıştır. Yüz ifadesi bağımsızlığının sağlanabilmesi için ağırlıklandırılmış benzerlik yaklaşımı geliştirilmiştir. Ağırlıklandırma yöntemiyle ifade değişikliğinin yüzde meydana getirdiği fazla değişimlere düşük ağırlık verilerek bu bölgenin etkinliği azaltılmaktadır ve böylece tanıma performansı artırılmak istenmektedir [47].

Tan ve ark. görüntülerdeki kapanmalara ve değişik ifadelere göre tanıma işlemi yapabilmek için parçalı benzerlik ilişkisi kurmuştur. İlk aşamada görüntü alt bloklara bölünmüştür. Daha sonra her alt blok için yerel öznelik vektörü bulunmuştur. Tanıma işleminin gerçekleştirilebilmesi için test görüntüsü ve eğitim görüntüleri arasındaki benzerlik bilgilerini içeren benzerlik matrisinin oluşturulması gereklidir. Test ve eğitim görüntüleri arasındaki uzaklık her bir parçanın birbirine olan

uzaklıklarının toplamı olarak alınmaktadır. Yazarlar tarafından geliştirilen bir hesaplama ve kesit değeri ile yüz benzer olan parçalar ve olmayan parçalar olmak üzere ikiye ayrılmaktadır. Test görüntüsünün eğitim görüntüsüne olan uzaklığı kesit değerine göre ağırlıklandırılmış toplam alınarak bulunur. Uzaklık değerlerinin hesaplanması için yazarlar tarafından farklı yöntemler sunulmuştur. Gerçek hayatta eşik değerleri sınıf bağımlı olmalıdır. Hesaplanan eşik değeri bir görüntünün doğru sınıfa atanmasını yüksek güvenilirlikte sağlamalıdır. Geliştirilen yöntemde her sınıfa (kişiye) ait kesit her biri için ayrı ayrı optimize edilmektedir. Uzaklık matrisi parça sayısına göre çok büyüyebileceğinden her bir yerel vektör SOM kullanılarak haritalanmıştır [21].

Jia ve Martinez çalışmalarında kapanma vb. problemlerin çözümü için yeniden inşa metodu geliştirmiştir. Buradaki temel fikir bir sınıfa ait bir test görüntüsünün, eğitim görüntülerinin doğrusal bileşkesi olarak düşünülebilmesidir. Hesaplanan ikili bir kapanma matrisi kullanılarak eksik pikseller hesaplanmıştır. Yeniden inşa işlemi kapanma olmayan pikseller kullanılarak yapılmaktadır. Yazarlar kapanma maskelerini hesaplarken ilk olarak PCA kullanarak yüzü tespit etmişler sonraki aşamada ise cilt rengini modelleyen Gauss karışımı kullanmışlardır. Daha sonra elde edilen görüntü değiştirici operatörlerle (erozyon ve birleştirme) temizlenmiştir. Son olarak elde edilen renk haritasıyla yüzün limitleri belirlenmiştir [43].


Gizli Markov Modeli (HMM) ses tanıma ve el yazısı tanıma gibi alanlarda yaygınca kullanılan bir yöntemdir. Huang ve ark. daha önceki çalışmalarda tüm yüzü kullanan HMM teknikleri yerine yerel ihtimalsele yaklaşım geliştirmişlerdir. Yazarlar tarafından yüz alın, gözler, burun, ağız ve çene olmak üzere 5 alt kısma bölünmüştür. Her bir kısım bir HMM ile ifade edilmektedir. Kapanma probleminin çözümü için kapanma HMM'leri de tanımlanmıştır (Gözlük HMM, Peçe HMM vb.). Örneğin peçe bulunan modelde ağız ve çene HMM'lerini yerine peçe kapanma HMM'si kullanılmıştır. Öznitelik oluşturma aşamasında HMM modellerinin kullanılabilmesi için gerekli izlem vektörleri soldan sağa ve yukarıdan aşağıya kayan bloklardan elde edilmektedir. Her izlem vektörü, (3x3) içerisinde yer alan en küçük 2D-DCT frekans ağırlıklarını içermektedir. Başlangıç olarak her eğitim

görüntüsündeki izlem vektörleri yüzün 5 kısmını gösterecek şekilde parçalanmıştır ve her parça o kısma karşılık gelen alt kısım HMM'lerin başlangıç parametrelerinin hesaplanması amacıyla kullanılmıştır. Eğitim işleminde birleştirilen HMM'ler her görüntü için standart geniş tek bir HMM gibi davranmaktadır. İzlem vektörlerinin benzerliği Viterbi algoritması ile tahmin edilir ve bu değer bilinmeyen bir nesnenin maksimum benzerlik kriterine göre tanınmasını sağlar [51].

Oh ve ark. LNMF (Local non-negative matrix factorization) yöntemi kullanarak bir tanıma yöntemi geliştirmişlerdir. İlk olarak görüntü 6 eşit ve kesişmeyen parçaya ayrılarak her bir parça için PCA ile boyut indirilmesi yapılmaktadır. Yazarlar kapanma olup olmadığına karar verebilmek için örnek sayısından olabildiğince bağımsız olan 1-NN sınıflandırıcı kullanmışlardır. Bu sınıflandırıcıda test edilen bir elemana en yakın komşusuna bakılır. Eğer komşu kapanma olan (outlier) bir sınıfın elemanına yakınsa kapanma olarak, değilse bir eşik değerine bakılarak karar verilir. Eğer parçanın en yakın kapanma olmayan komşusuna uzaklığı eşik değerinden büyükse bu eleman kapanma olan sınıfa ait diye atanmaktadır. Kapanmaların atılması aşamasında önceden tespit edilen pikseller kullanılarak her bir LNMF katsayısında eleme yapılır. Geriye kalan katsayılarla LNMF hesaplanır [2].

Kim ve ark. alt uzay tekniklerini incelemişler ve yeni bir metod geliştirmişlerdir. Alt uzay oluşturma tabanlı yöntemlerin tanımlama özellikleri oluşturdukları temel görüntülerle ilişkilidir. PCA ve ICA mimarisi II temelli görüntüler genel özellikleri vurgulamaktadır. ICA mimarisi I diğerlerine oranla yerel özellikleri daha iyi vurgulamaktadır. Dolayısıyla kapanmalar ve ifade değişimleri olan veri setlerinde daha iyi performans sergilemektedir. Fakat ICA I tabanlı görüntüler lokal belirgin özellikleri vurgulamakta yeterli değildir çünkü hala vurgulu olmayan bölgelerde yer alan pikseller tanıma performansını düşürmektedir. LNMF temelli görüntülerde yerel öznitelikler iyi vurgulanabilmesine rağmen her zaman gerekli bölgelerin vurgulanacağı garanti değildir. Bu kapsamda yazarlar tarafından geliştirilen LS-ICA (Locally Salient ICA) tabanlı görüntülerde sadece belirgin bölgeleri vurgulanmaktadır ve bu bölgeler ayırt ediciliği yüksek olan göz, kaş, burun ve dudaklar gibi bölgelere karşılık gelmektedir. LS-ICA tabanlı görüntüler iki aşamada

oluşturulmaktadır. İlk aşama parça tabanlı yerel vurgulu temel görüntülerin ICA-I ile oluşturulmasıyla ilgilidir. İkinci aşamada elde edilen temel görüntüler tanıma performansının artması için sınıf bölücülüğü ölçütüne (entropy) göre sıralanır. LS-ICA metodu kurtosis maksimizasyonu sırasında ek yerleştirme sabitleri kullanarak parça tabanlı yerel vurgulu görüntüleri oluşturmaktadır. İşlem sırasında her iterasyonda ağırlıklandırılarak elde edilen sonuç büyük piksellerin vurgulanmasıyla daha seyrek bir hale gelir. Bu seyrelme yerleştirmeyi tanımlamaktadır. Alt uzay tekniklerinden elde edilen temel görüntüler Şekil 3.1’de verilmiştir [16].



Şekil 3.1. a) PCA, b) ICA, c) ICA mimarisi II, d) LS-ICA, e) LNMF, f) LFA [51]

Yukarıdaki deneylerde aynı görüntünün farklı alt uzay teknikleri kullanılarak hesaplanan temel görüntülerinde vurgulanan kısımlar gösterilmektedir. PCA’da herhangi bir vurgu söz konusu değilken ICA’da gözler, kaşlar ve burun gibi ayırt ediciliği yüksek bölgeler vurgulanmaktadır.

Min ve ark. kapanmaları görüntüden eleyerek geri kalan kısım üzerinden tanıma yapmaya çalışmışlardır. İlk aşamada görüntü, üzerindeki kapanmaların tespit edilebilmesi için parçalara bölünmüştür. Kapanmaların tespitinde yazarlar sadece gözlük ve peçe ile kapanmaları dikkate almıştır. Bu sebeple yüz alt ve üst olmak iki eşit parçaya bölünmüştür. Gözlük olanlarda alt kısım, peçe olanlarda üst kısım tanıma amaçlı kullanılmıştır. İki parçaya ayrılan yüzde her bir parçaya karşılık gelen Gabor dalgacık öznitelikleri hesaplanmıştır. Gabor dalgacıları hesaplandıktan sonra 2-D konvolüsyon kullanılarak öznitelik oluşturma işlemi gerçekleştirilmiştir. Daha sonra öznitelik vektörü üzerinde PCA kullanılarak boyut indirgeme yapılmıştır. Son aşamada SVM kullanılarak kapanmanın varlığına veya yokluğuna karar verilmiştir. Tanıma aşamasında kapanma olmayan görüntü eşit parçalara ayrılmıştır. Her bir parça için LBP (Local Binary Patterns) öznitelikleri hesaplanmış ve LBP kodları histogramlar içinde toplanmıştır. Daha sonra elde edilen tüm histogramlar birleştirilerek tek bir histogram haline getirilmiştir. Sınıflandırma işlemi histogramlar arasındaki benzerliğe bakılarak yapılmaktadır. Tanıma için NN sınıflandırıcısı ve Chi-square uzaklığı kullanılmıştır. Histogram kullanılarak tanıma işlemi ile ışıklandırmadan ve duruştan kaynaklanan sapmalar minimize edilmiştir [32].

Deng ve ark. çalışmalarında kapanma olan görüntüler üzerinde tanıma performansını artırabilmek için bu kapanan kısımların onarılmasını sağlayan bir metot geliştirmişlerdir. SR tekniği ile arama yapılarak eksik yüze en yakın tam yüzler bulunmaktadır. Daha sonra ilgili bölgeye en iyi oturacak parça bulunarak graf temelli bir yöntemle görüntüye monte edilmektedir. Kapanmaların bu yöntemle onarılmış halleri Şekil 3.2’de verilmiştir [44].



Şekil 3.2. Kapanma içeren görüntüler ve onarılmış halleri [44]

Tan ve ark. çalışmalarında SOM kullanarak kapanma problemine çözüm üretmeye çalışmışlardır. Sınıflandırma algoritması olarak SOM öznelikleri ile uyumlu olan ve bir güvenilirlik ölçütüne göre çalışan kNN sınıflandırma algoritmasını tercih etmişlerdir. Görüntü lokalizasyonu aşamasında boyut indirgemesi için ışıklandırma vb. sebeplerden fazla etkilenen PCA yöntemi yerine 2DPCA yöntemini kullanmışlardır. 2DPCA 1 boyutlu vektörler yerine küçük 2 boyutlu görüntü matrisleri kullanmaktadır. Bu nedenle küçük örnek boyutu probleminin çözümüne daha uygundur. Yazarlar tarafından görüntü $M=l/d$ eşit boyuttaki parçaya bölünmektedir. Burada l bir parçanın boyutu d ise tüm görüntünün boyutudur. SOM eğitildikten sonra her bir görüntüye ait her bir alt blok en yakın komşuluğu mantığıyla BMU'lara (Best Matching Units) haritalanmıştır. Yukarıda anlatılan tekli SOM yönteminin yanı sıra çoklu SOM tekniği de alternatiftir. Diğer teknikte her bir sınıf için ayrı ayrı SOM hesaplanır ve tanıma işlemi test görüntüsünün her bir SOM kullanılarak alınan yansıması kullanılarak yapılır. Sınıflandırma işlemi yerel vektörler üzerinden yapılmaktadır [22].

Zhang ve ark. bu çalışmada KLD (Kullback-Leibler Divergence) tabanlı LGBP (Local Gabor Binary Patterns) kullanan bir yüz tanıma sistemi geliştirmişlerdir. LGBP ifade, ışıklandırma, yaşlanma gibi yüz üzerinde değişiklik meydana getiren sebeplere karşı iyi sonuç vermektedir. Bu metot Gabor dönüşümü, LBP ve lokal


histogramın özelliklerinden faydalanmaktadır. LGBP 3 aşamada uygulanmaktadır. LGBP operatörü kullanılarak yüzün değişik ölçeklerde ve oryantasyonlarda LGBP görüntüleri elde edilmektedir. Daha sonra her bir lokal bölge için histogramlar hesaplanmaktadır. Tüm histogramlar birleştirilerek öznitelik vektörü oluşturulmaktadır. Kapanma problemin çözümü için ağırlıklandırma işlemine gidilmiştir. Eğer bir bölge tamamen kapanmış ise ağırlığı sıfıra eşitlenmeli, bir kısmı kapanmış ise ağırlık değeri düşürülmelidir. Bir test histogramının kapanma ihtimali ortalama histogramdan sapması olarak düşünülmektedir. Bu amaçla KLD kullanılmıştır [33].

Rama ve ark. tarafından PCA, CPCA (Component based PCA) ve LPCA (Lophoscopic PCA) yöntemlerinin kapanma olan görüntülerdeki tanıma başarıları incelenmiştir. Deneyler farklı birleştirme teknikleri kullanılarak yapılmıştır. Parçalı çalışan metotların kapanma problemlerinde dahi iyi sonuç verdiğini ileri sürmektedirler [4].

Jia ve Martinez çalışmalarında yüz tanıma yöntemine kendi modifiye ettikleri SVM yapısını kullanarak kapanma problemine çözüm üretmeye çalışmışlardır. Klasik SVM’de destek vektörleri üzerinden geçen sınır alanını maksimize ederek iki sınıfı ayıran en iyi sanal düzlem bulunmaya çalışılmaktadır. Klasik SVM’de bazı özniteliklerin kaybolması durumunda yanlış sınıflandırma yapılabilmektedir. Bu problem kayıp piksellerin tahmin edilmesiyle çözülebilir fakat kayıp piksellerin uygun değerlerinin tahmin edilmesi ayrı bir problemdir. Bu durum Şekil 3.3’de gösterilmiştir [45].

Şekil 3.3’de p_3 noktasının f_2 koordinatı kayıptır. q noktaları bir sınıfa ve p noktaları diğer sınıfa ait olmak üzere p_3 noktasının olası 3 farklı f_2 değeri için (p_3^1, p_3^2, p_3^3) çizilen düzlemlerin (l_1, l_2, l_3) hiçbiri için tüm p_3 noktaları doğru sınıflandırılmaz. Bu amaçla verinin Gauss dağılımına uygun olduğu varsayılarak olasılık temelli bir yaklaşımla eksik veriler üzerinde çalışan SVM tasarlanmıştır. Eksik veriler üzerinde çalışan SVM tasarlandıktan sonra tamamlanmış test vektörlerinin oluşturulması

gerekmektedir. Bu amaçla kayıp özniteliklerin hesaplanabilmesi için doğrusal bir yakınsama yaklaşımı kullanmışlardır.



Şekil 3.3. Tamamlanmamış öznitelik noktası p3 ve farklı düzlemler [46]

Naseem ve ark. doğrusal bir yakınsama metodu geliştirerek tanıma algoritması ortaya koymuşlardır. Bir test görüntüsü eğitim görüntüsü içindeki aynı sınıfa ait görüntülerin doğrusal bileşkesi olarak ifade edilmektedir. Optimizasyon problemi en küçük kareler yöntemiyle çözülmüştür. Kapanma problemlerinin çözümünde görüntü birbiriyle çakışmayan belirli sayıda kare alana bölünerek her bir alan için yeniden oluşturulan görüntüler ile test görüntüleri arasındaki fark hesaplanmaktadır. Son olarak tüm hesaplanan uzaklıklar ve bunlara karşılık gelen sınıf değerleri arasından minimum uzaklığa sahip parçanın kararı görüntünün sınıfı olarak atanmaktadır [46].

BOW (Bag of Words) nesne tanıma problemlerine kullanılabilen etkili bir yöntemdir. Fakat yüz tanıma probleminde yüzler aynı nesneye kategorisine girdiği için yüzler arasındaki ayırt ediciliği düşüktür. Bu sebeple bu çalışmanın yüz tanıma probleminde kullanılabilmesi için Li ve ark. tarafından BBOW (Block-based Bag of Words) geliştirilmiştir. Görüntüler ilk aşamada 5x5 bloklara ayrılmıştır. Her bir parçaya yazarlar tarafından ROI (Region of interest) olarak adlandırılmıştır. Her ROI için örnekleme ızgarası üzerinde yoğun SIFT vektörleri hesaplanmıştır. 128 boyutlu SIFT vektörü bir örnekleme ızgarasına karşılık gelmektedir. Bu işlemlerden sonra her bir blok için bir SIFT vektörü seti elde edilmiş olur. Eğitim aşamasında her bir ROI'nin

SIFT vektörleri k-ortalamar algoritması kullanılarak kod kelimelerine dönüştürülmüştür. Her bir ROI içerisindeki farklı ızgaraların SIFT vektörleri k-ortalamar algoritması kullanılarak K kümeye ayrılmıştır. Bir kod kelimesi öğrenilen bir kümenin merkezi olarak tanımlanmaktadır ve bu değer bloğa ait SIFT vektörleri kümesinin eğitim kümesindeki temsilcisidir. Bir kod kitabı bir ROI'ye ait K tane kod kelimesi içerir. Bu işlem sonunda eğitim kümesi üzerinden 5x5 kod kitapları oluşturulmuş olur. Sonuç olarak her bir ROI'ye ait kayan ızgara üzerindeki her bir SIFT vektörü bir kod kelimesine haritalanmış olur. Bir görüntünün bir bloğu histogramlar kullanılarak sayılan farklı kod kelimelerinin sayısı ile temsil edilir. Daha sonra 5x5 histogramlar birleştirilerek tüm görüntünün temsilcisi elde edilir. Doğrusal SVM'ler ile her bir farklı sınıfın histogramları kullanılarak eğitim gerçekleştirilir. Test aşamasında, kullanılan görüntü eğitim kod kitapları kullanılarak 5x5 kod kelimesi histogramlarına dönüştürülür ve eğitilen SVM'ler kullanılarak sınıflandırma yapılır. Bu çalışmada AR veri tabanında yapılan deneylerde çok yüksek başarı oranları elde edilmiştir [60].

Wright ve ark. alt örnekleme ve rastgele öznelik seçme yöntemlerinin "Eigenfaces" ve "Laplacianfaces" gibi yöntemlerle kıyaslandığında SRC'de aynı başarı oranlarının elde edilebildiğini göstermişlerdir. Çalışmalarında klasik SR ifadesinin kapanmalara dayanıklı versiyonunu geliştirmişlerdir. Yazarlar SRC'yi hem bütüncül olarak hem de yerel olarak denemiş ve kapanma probleminde yerel yaklaşımın daha iyi sonuç verdiğini göstermişlerdir [35].

Lai ve Jiang parçaladıkları görüntünün kapanan kısımlarını belirleyebilmek için SR kullanmışlardır. Yazarlar SR aşamasında elde edilen katsayılar ve fark değerlerini kullanarak kendi belirledikleri eşik değerleriyle karşılaştırıp kapanma olup olmadığına karar vermektedir. Sınıflandırma aşaması ağırlıklandırılan veriler kullanılarak yine SR ile yapılmaktadır [36].

Yang ve ark. kapanmaları kendi geliştirdikleri bir yakınsama algoritmasıyla elde ettikleri ağırlık katsayılarını içeren bir maske ile tespit etmektedir. Tanıma

aşamasında SR benzeri bir doğrusal yakınsama yöntemi ile bu maske ile ağırlıklandırılan test ve eğitim görüntüleri kullanılmaktadır [37].


Shin ve ark. çalışmalarında modifiye edilmiş MacGergor yapay sinir ağı modelini ve kendi geliştirdikleri hatırlama yöntemiyle kapanma ve değişik açılarda çevrilmiş görüntüleri tanımaya çalışmışlardır. Yapay sinir ağı öznelik çıkarım katmanı ve tanıma katmanı olmak üzere iki katmandan oluşmaktadır. Tanıma işlemi tanıma katmanının oluşturduğu sinyal dizisine göre yapılmaktadır. Bu sinyal dizisi daha önce her sınıf için elde edilen sinyal dizileriyle karşılaştırılmakta ve tanımada en çok benzeyen sınıfın etiketi kullanılmaktadır. Eğitim aşamasında eğitilecek görüntünün değişik pozlarda elde edilmiş ve değişik bölgelerde yapay kapanma içeren görüntüleri kullanılmaktadır [23].

Shermina ve Vasudevan öklit uzaklığı kullanılarak blok eşleşmesi mantığıyla kapanma problemini çözmeye çalışmışlardır. Tanıma işlemi PCA ile yapılmaktadır [7].

4. GELİŞTİRİLEN YÖNTEM

4.1. Yöntemin Çalışma Şekli

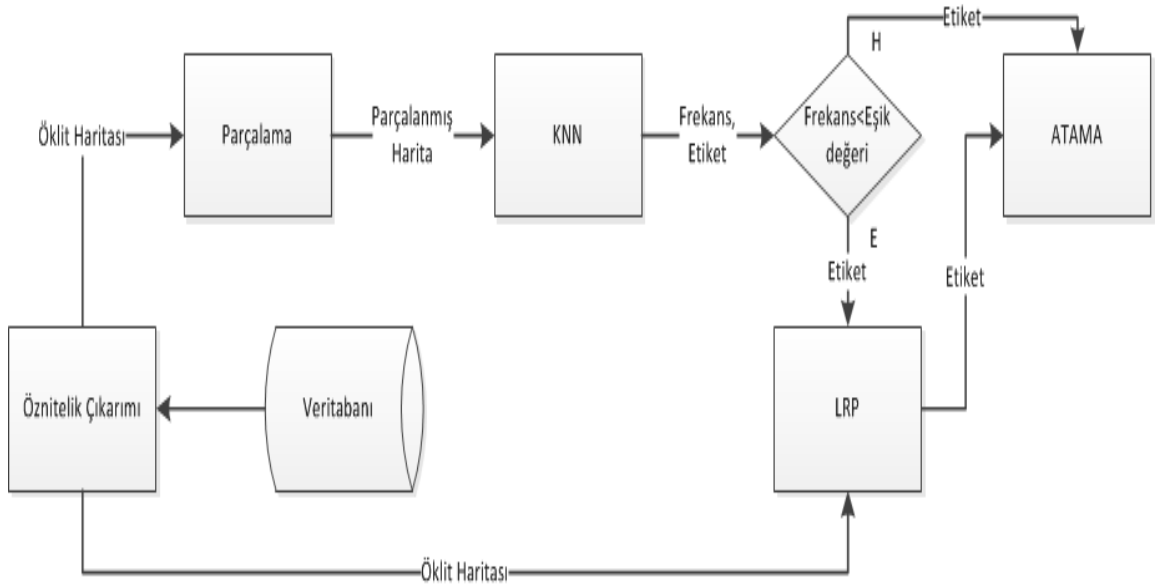
Deneysel Matlab yazılımı kullanılarak gerçekleştirilmiştir. Geliştirilen yöntem kNN ve LRP (Linear Regression Predictor, Doğrusal Regresyon Belirleyicisi) olmak üzere iki aşamalı sınıflandırma yapan bir yapıdadır. İlk aşamada görüntülerin Öklit haritaları hesaplanarak görüntülerden renk bilgisi ayrıştırılmakta ve istenmeyen değişimler görüntüden atılarak öznelik seçimi yapılmaktadır. Tanıma işleminin ikinci aşamasında öklit haritası eşit ve birbiriyle çakışmayan 25 kare parçaya bölünmektedir (Şekil 4.1).



Şekil 4.1. Öklit haritasının parçalanması
a) Parçalanmamış harita b) Parçalanmış harita

Sonraki aşamada her bir parça kNN sınıflandırıcısıyla ayrı ayrı sınıflandırılmaktadır. Elde edilen parçalar en çok oy alan mantığına göre değerlendirilmekte, en yüksek oyu alan sınıfın oy miktarı bir frekans eşik değeri ile karşılaştırılmaktadır. Bu değer eşik değerinden küçük ise eşlesen tüm sınıfların etiketleri LRP sınıflandırıcısına gönderilmektedir, aksi durumda sınıfın etiketi olarak doğrudan sonuç olarak atanmaktadır. LRP sınıflandırıcısına bu durumda en fazla parça sayısı kadar değişik sınıf etiketi gönderilebilmektedir. Son olarak LRP sınıflandırıcısından geçen veriler

bu sınıflandırıcının verdiği karara göre atanır. Bu durum Şekil 4.2'de gösterilmektedir.



Şekil 4.2. Sistemin blok diyagramı

4.2. Sınıflandırma

Sınıflandırma işlemi iki aşamada yapılmaktadır. Öznitelik çıkarımı adımından elde edilen öklit haritaları 25 eş ve çakışmayan kare parçaya bölünerek kNN sınıflandırıcısı ile sınıflandırılmaktadır. kNN sınıflandırıcısının sonucunda her bir parça için ayrı ayrı etiket değerleri oluşmaktadır. En çok atanan etiketin sayısı (frekansı) 5'ten küçükse tüm eşsiz etiketler LRP sınıflandırıcısına gönderilerek seçimin burada yapılması sağlanmaktadır. Aksi durumda en çok tekrar eden etiket test edilen görüntünün etiketi olarak atanmaktadır.


4.3. kNN (k – Nearest Neighbour, k-En Yakın Komşu) Sınıflandırıcısı

SRC NN ve NS (Nearest Subspace, En yakın alt uzay) sınıflandırıcılarının geliştirilmiş hali olarak düşünülebilmektedir. NN sınıflandırıcıları sınıflandırmayı

testi temsil eden en iyi tek eğitim örneğine göre yaparken, NS sınıflandırıcıları sınıflandırma işlemini her bir sınıf için her bir eğitim örneğinin en iyi doğrusal kombinasyonuna göre yapmaktadır [35]. Bu sebeple iki aşamalı oluşturulacak yapıda sistemin benzer yöntemler kullanarak çalışması açısından sınıflandırma ve komşuluk seçimi amacıyla kullanılacak sınıflandırıcı için kNN sınıflandırıcısı tercih edilmiştir. Görüntüler parçalara ayrılarak kNN sınıflandırıcısının komşuluk seçme özelliği genişletilmiştir ve kapanmalara karşı dayanıklılık sağlanmıştır.

kNN sınıflandırıcısı en popüler sınıflandırıcılardan biridir. Sınıflandırma işlemi sınıflandırılacak elemanın en yakın k komşusuna bakılarak yapılır. Elemanın sınıfı en yakın k komşuluğunda aynı sınıf içinde yer alan en çok sayıdaki elemanın sınıfı olarak atanır.

Şekil 4.3’de sınıfı belirsiz olan elemanın sınıfı en yakın 3 komşuluğuna bakıldığında üçgen sınıf olarak atanacaktır.



Şekil 4.3. kNN sınıflandırıcısının çalışma şekli

Uzaklık ölçütü olarak genellikle Öklit uzaklığı kullanılır. Fakat uygulanma alanına göre kosinüs uzaklığı gibi değişik uzaklık hesaplama yöntemleri de tercih edilebilmektedir.

4.4. LRP (Linear Regression Predictor) Sınıflandırıcısı

LRP, Naseem ve ark. [46] tarafından geliştirilen yöntemle aynı yapıdadır. Fakat katsayıların elde edilmesi aşamasında yeniden inşa için aynı sınıfın örneklerini değil gönderilen tüm sınıfların eğitim görüntülerini aynı anda kullanmaktadır. Bu özelliği ile sınıflar arası ilişkileri de değerlendirmiş olmaktadır. Ayrıca bu yapı tek örnek durumunda da algoritmanın çalışabilmesini sağlamaktadır. LRP geliştirilen yöntemin yapısından dolayı her durumda aşırı tanımlı (bkz. Bölüm 2.4.1) olarak çalışmaktadır. Aksi durum söz konusu olursa Bölüm 2.4.2’de belirtilen algoritmaların biri en küçük kareler yaklaşımının yerine kullanılabilir.

Sırasıyla Eş. 2.5 ve Eş. 2.3 kullanılarak katsayılar elde edildikten sonra sınıf atamasında kullanılacak çeşitli yöntemler vardır. Bunlardan biri en yüksek katsayıya sahip eğitim kümesinin etiketini atamak, diğeri ise elde edilen katsayılar kullanılarak her bir sınıf için Eş. 4.1 kullanılarak görüntüleri yeniden oluşturmak ve test ile en az uzaklığa sahip görüntüye atamaktır.

Yeni sınıf olarak atanacak i etiketi yeniden oluşturma sonucu oluşan farkların en küçüğü baz alınarak yapılır.


$$i = \operatorname{argmin}_i \|y - A\delta(x)\| \quad (4.1)$$

Eşitlikte y test vektörünü A eğitim matrisini ve x katsayılar vektörünü belirtmektedir. δ fonksiyonu aynı sınıfa ait katsayıları seçen fonksiyondur.

4.5. Öznitelik Çıkarımı ve Seçimi

Yüzler arasında tanıma yaparken tanıma işlemini başarısızlığa götürebilecek birçok ayrıntı söz konudur. Ayrıca tanıma sistemine esas olan ayrıntıların ağırlıklandırılması gerekebilmektedir. Bu duruma örnek olarak seçim örneği gösterilebilir (Şekil 4.4).

Yalnızca Şekil 4.4’de yer alan bilgilere dayanarak seçimi hangi partinin kazanacağına karar vermek istenirse renklere bakarak en çok alanı kapsayan sarı partinin seçimi kazanacağı sonucuna varılması yanlıştır, çünkü renkler ne kadar geniş bir alanı kaplarsa kaplasın aynı harita üzerinde nüfus yoğunluğunda değerlendirilmesi gerekir. Bu amaçla nüfus barındırmayan deniz gibi çok alçak, dağlar gibi çok yüksek yerlerin haritadan çıkarılması gerekir. Ayrıca nüfus yoğunluğu çok olan coğrafi bölgelerin de ağırlıklandırılması gerekmektedir. Burada yerleşim yeri olmayan yerlerin haritadan atılması öznitelik seçimine, nüfus yoğunluğuna göre haritanın ağırlıklandırılması öznitelik çıkarımına, ağırlıklandırılmış en çok bölgeyi tutan partinin seçimi kazanacağı sonucuna ulaşılması ise birleştirme ve sınıflandırmaya örnek olarak gösterilebilir.



Şekil 4.4. Türkiye 2002 seçim haritası

Yüz tanıma sisteminin başarısını artırabilmek için yüz üzerindeki çok düşük ve çok yüksek değişimlerin çıkarılması, bunların dışındakilerin ise ağırlıklandırılması gerekmektedir. İnsanların da seçim örneğindeki önermeye paralel olarak çok düşük ve çok yüksek değişimleri tanıma esnasında kullanmadıkları düşünülmektedir. Buna örnek olarak insanların algılarının kısıtlı olması ve yalnızca belirli dalga boyu

aralığındaki renkleri görebilmesi veya belirli frekans aralığındaki sesleri duyabilmesi de gösterilebilir.

Yüz üzerindeki değişimlerin elde edilmesi için yüzün Öklit haritası çıkarılmaktadır. $M \in R^{h \times w}$ bir matris olmak üzere h ve w sırasıyla görüntünün yüksekliği ve boyunu, $X \in R^{h \times w}$ bir matris olmak üzere elde edilen Öklit haritasını ve $f(a,b)$ ise M üzerinde (a,b) konumunda yer alan pikselin komşuluğundaki pikselleri seçen ve değerlerini döndüren fonksiyonu belirtmektedir. Öklit haritasında yer alacak bir pikselin değeri M matrisinde aynı konumda yer alan pikselin komşu piksellerine toplam uzaklığı bulunarak hesaplanır.

$$X_{a,b} = \|\|c - f(a,b)\|\| \quad (4.2)$$

$$c = \{M_{a,b}, M_{a,b}, \dots, M_{a,b}\}$$

Yukarıdaki fonksiyonda dikkat edilmesi gereken unsur iki vektörün arasındaki uzaklık hesaplamasıdır. Yani f fonksiyonunun seçtiği komşuluk değerleri $v \in R^k$ ve k komşuluk sayısı olmak üzere, bir noktadaki değişim değeri merkez vektörü $c \in R^k$ ile komşuluk vektörü v arasındaki öklit uzaklığına eşittir. c vektörü değişim değeri hesaplanacak pikselin değerlerinin k kere tekrar edilmesiyle elde edilir.

Örneğin; komşuluk vektörü $v = \{1, 2, 3, 4, 5, 6, 7, 8\}$ olan bir pikselin değeri 9 ise, komşuluk prensibine dayanarak $c = \{9, 9, 9, 9, 9, 9, 9, 9\}$ olarak kabul edilebilir. Dolayısıyla iki vektörün arasındaki değişim aynı zamanda uzaklıkla ifade edilebileceğinden Öklit hesaplamasıyla bulunabilir. Ayrıca Öklit işleminin karesel olmasından dolayı negatif – pozitif değişimlerin birbirini söndürmesi de engellenmiş olmaktadır.

Öklit işleminden önce renkli görüntüler için görüntünün gri seviye indirgenmesi gerekmektedir. Bu amaçla RGB (Red, Green, Blue) değerlerinin katsayıları olarak, TV ve video sistemlerinde (PAL (Phase Alternating Line), NTSC (National Television System Committee)) kullanılan yuvarlanmış şekilleriyle sırasıyla 0,3, 0,59

ve 0,11 değerleri kullanılmıştır. f fonksiyonu değişik geometrilere seçim yapabileceği gibi hazırlanan yöntemde pikselin çevresindeki 8 komşu pikselin değerini seçmektedir. Eş. 4.2'nin görüntüye uygulanmasıyla Şekil 4.5'te gösterilen dönüşüm gerçekleştirilmektedir. Dönüşüm değeri 255 değerinden büyük olan piksellerin değeri 255'e sabitlenmiştir.



Şekil 4.5. Öklit haritasının elde edilmesi

Şekil 4.5'te görülen haritada siyah alanların geniş yer kapladığı bölgelerde piksel değerleri 0 değerine yakın değerlerdir, fakat çoğunluğu 0 değildir. Bu durum piksel değeri alt sınırı olarak 5 seçilirse ve pikselin değeri bu değer üzerindeyse 255 ve aksi durumu için 0 olarak atanırsa açıkça görülebilmektedir (Şekil 4.6).



Şekil 4.6. Değişimlerin çoğunluğunun yansıtılması

Şekil 4.5'den ve Şekil 4.6'dan da anlaşılacağı gibi doğru deęişim aralığının bulunup vurgulanması ve aralık dıőında yer alan deęişimlerin atılması gerekmektedir. Deęişimlerin çoęunluęunu düşük deęerler oluőturduęu için alt sınırın seęilmesi bu aőama için kritik olan aőamadır. Bu seęimle ilgili yapılan incelemeler deneysel çalıőmalar bölümünde açıklanmıőtır.

Yukarıda anlatılan öklit haritası mantığına benzer olarak ıőıklandırmanın ve kapanmanın aőırı etkisinden kurtulmak için WLD (Weber Local Descriptor) kullanılmıőtır [38]. WLD ile elde edilen görüntüler Şekil 4.7'de verildięi gibidir.



Şekil 4.7. WLD ile elde edilmiő görüntüler [38]

İlk satır orijinal görüntüler, ikinci satır WLD karőılıkları

WLD gibi bir teknięin SR yöntemlerinde baőarı oranını artırabileceęi gösterilmiőtir [38]. Bu yüzden tezde deęişimler üzerinde hesaplama yapılabilir ve WLD benzeri bir etkiyi saęlayabilecek öznitelik yapısına sahip olan Öklit haritası yöntemi geliőtirilmifitir.

5. DENEYSEL ÇALIŞMALAR

Aksi belirtilmedikçe yapılan deneylerde ilk aşama sınıflandırıcı güven frekansı olarak 5 değeri kullanılmıştır. Güven frekansı kNN tarafından sınıflandırılan parçalardan en çok oyu alan etiket in oy sayısının karşılaştırıldığı eşik değeridir. Alt örnekleme “bicubic” ara değerlendirme yöntemi kullanılarak yapılmaktadır. LRP adımından önce veriler normalize edilmektedir (unit ℓ_2 norm). Görüntü 5x5 ızgara biçiminde birbiriyle çakışmayan 25 kare parçaya ayrılmaktadır.

5.1. AR Veri tabanı

AR veri tabanı 126 (70 Erkek ve 56 Kadın) farklı kişiye ait 4000'nin üzerinde renkli görüntü içerir [87]. Bu görüntüler ifade değişimleri, gözlük ve peçe olmak üzere kapanma ve ışıklandırma gibi olumsuz durumları içermektedir. Görüntüler 2 hafta arayla iki oturumda elde edilmiştir. Tablolarda belirtilen kodların ilk oturum için açıklamaları aşağıdaki gibidir:


- E : İfade etkisi
- I : Işık etkisi
- O : Kapanma etkisi
- AR 1 : İfade değişimi olmayan
- AR 2 : Gülümseme
- AR 3 : Sinirli
- AR 4 : Bağırma
- AR 5 : Soldan ışık
- AR 6 : Sağdan ışık
- AR 7 : Önden ışık
- AR 8 : Gözlük
- AR 9 : Gözlük ve solda ışık
- AR 10 : Gözlük ve sağdan ışık
- AR 11 : Peçe
- AR 12 : Peçe ve soldan ışık

AR 13 : Peçe ve sağdan ışık

Yukarıdaki durumlar dışında yer alan ve ikinci oturumdaki görüntüleri ifade eden AR14-AR26 değerlerinin karşılığı sırasıyla ilk oturumla aynıdır.

Deneylede daha önceden hazırlanmış kesilmiş görüntüler kullanılmıştır [76]. Bu veri seti AR veri tabanında yer alan 50 erkek ve 50 bayanın kesilmiş görüntülerini içermektedir.

Şekil 5.1'de ifade, kapanma ve ışıklandırma değişimlerini içeren görüntüler gösterilmektedir. İlk satırda yer alan görüntüler ifade değişimini içeren görüntülerdir (E) ve sırasıyla AR 1-4 ile adlandırılmıştır. İkinci satırda yer alan görüntüler ışıklandırma değişimlerini içerir (I) ve sırasıyla AR 5-7 olarak isimlendirilmiştir. Üçüncü satırda yer alan görüntüler gözlüklü görüntülerdir (O) ve bu görüntüler sırasıyla AR 8-10 olarak adlandırılmıştır. Son satırdaki görüntüler ise peçeli görüntülerdir (O) ve bu görüntüler sırasıyla AR 11-13 olarak adlandırılmıştır. Peçeli görüntüler yaklaşık %40, gözlüklü görüntüler ise yaklaşık %20 kapanma oranına sahiptir.

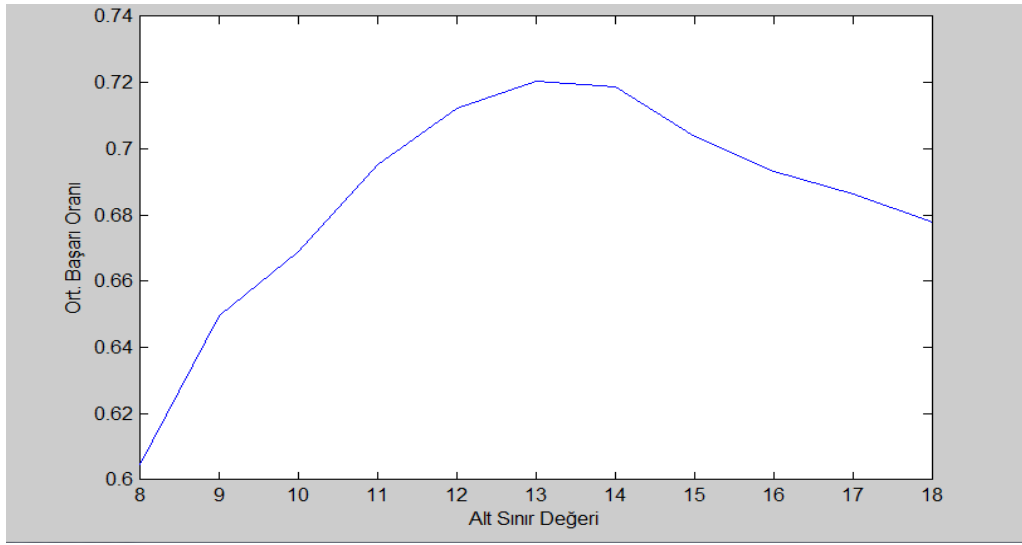


Şekil 5.1. AR veri tabanında yer alan yüz görüntüleri

5.2. Öklit Haritasında Kullanılacak Alt Sınırın Bulunması

Öklit haritasının alt sınır değeri hesaplanırken ilk oturumda yer alan 100 kişinin ifade değişimi olmayan (AR1) 100 görüntüsü eğitim amacıyla ve aynı kişilerin gözlüklü, peçeli ve aynı zamanda soldan ve sağdan ışık alan 100'er görüntüsü test amacıyla kullanılmıştır (AR9, AR10, AR12, AR13). Deneyler alt sınır değerleri 8 ile 18 arasında değişmek üzere her bir alt sınır değeri için 20x20, 25x25, 30x30, ... , 85x85, 90x90 alt örnekleme miktarlarının her biri için ayrı ayrı yapılmış ve elde edilen başarı oranlarının ortalamalarının alt sınır değerine göre değişimi Şekil 5.2'deki grafikte verilmiştir. Test setinin ışıklandırma içeren görüntülerden seçilmesindeki amaç yüksek değişim aralığının atılmasıyla oluşacak olumsuz durumdan dolayı meydana gelebilecek problemlere karşı algoritmayı dayanıklı hale getirmek ve bu özelliği bir cezalandırıcı olarak kabul ederek bir denge unsuru olarak kullanmak, dolayısıyla daha sağlıklı bir seçim yapmaktır.

Şekil 5.2 incelendiğinde en iyi alt sınır değerinin 13 değeri olduğu görülmektedir. 13 değerinden önce grafikte görülen başarı oranındaki artış eğiminin 13 değerinden sonra düşüş eğimine göre fazla olması 13 değerinden önce değişimlerin fazla oluşu ve başarı oranını artırması elenen değişimlerin başarı oranına etkisinin pozitif olmasından kaynaklanmaktadır. 13 değerinden sonra oluşan eğimin düşük olması bu değerden sonra elenen değişim miktarının azalmasından kaynaklanmaktadır.



Şekil 5.2. Geniş alt örnekleme aralığına göre elde edilmiş alt sınır ve ortalama başarı oranı grafiği

Öklit alt sınırının değişim oranına göre başarı oranlarının nasıl değiştiğini incelemek amacıyla yukarıda belirtilen deneye ek olarak ilk oturumdaki ifade değişimi olmayan (AR1) 100 kişinin 100 görüntüsü eğitim amacıyla, aynı kişilerin gözlüklü ve peçeli (AR8, AR11) 100'er görüntüsü test amacıyla kullanılmıştır. Deneyler 90x90 ve 45x45 alt örnekleme miktarında yapılmış ve elde edilen sonuçlar sırasıyla Çizelge 5.1 ve Çizelge 5.2'de verilmiştir.

Çizelge 5.1'de başarı oranları incelendiğinde 11, 12 ve 13 arasında başarı oranları çok yakın olduğundan dolayı seçim yapmak zordur. Bu alt sınırlar kullanılarak 45x45 alt örneklemede deneyler tekrar edilmiştir. Yüksek değerlerde fazla değişim kaybedilmesinden dolayı ışıktan kaynaklanan bozulmalara karşı dayanıklılık azalacaktır. Bu sebeple görüntüden fazla değişim atılması uygun değildir.


Çizelge 5.1. 90x90 alt örneklemede öklit sınırlarının başarıya etkisi

Alt Sınır Değeri	Başarı Oranı (%)	
	Gözlüklü	Peçeli
8	96	83
9	95	87
10	97	90
11	98	93
12	98	93
13	97	93
14	98	90
15	97	91
16	96	94
17	94	93
18	94	93

Çizelge 5.2 incelendiğinde en iyi başarı oranının 13 değerinde elde edildiği görülebilmektedir. Yapılan deneyler sonucunda en iyi başarı oranlarını veren parametrelerden alt limit olarak 13 değeri ve üst limit olarak 50 değeri seçilmiştir. Bu değerler kullanılarak elde edilmiş görüntü Şekil 5.3'de verilmiştir. Şekil 5.3'deki görüntü elde edilirken aralık dışında yer alan değişim değerleri 0, aralık içinde yer alan değişim değerleri 255 olarak atanmıştır. 13 ve 50 değerleri aralığa dahil değildir. Tanıma işleminde elde edilen son görüntü kullanılmaktadır.

Çizelge 5.2. 45x45 alt örneklemede öklit sınırlarının başarıya etkisi

Alt Sınır Değeri	Başarı Oranı (%)	
	Gözlüklü	Peçeli
8	93	87
9	95	88
10	95	91
11	98	90
12	97	94
13	98	96
14	98	93
15	98	94
16	97	94
17	97	93
18	97	93



Şekil 5.3. Seçilen değişim aralığı kullanılarak elde edilen öklit haritası
a) Normal görüntü b) Gözlüklü görüntü c) Peçeli görüntü

5.3. En iyi Alt Örneklem Miktarının Belirlenmesi

Alt örneklem oranları yüz tanıma sistemlerinde başarı oranlarını ve işletim maliyetlerini etkilemektedir. Düşük alt örneklemelerde başarı oranı yükselirken işlem maliyetinden de tasarruf edilebilmektedir. Alt örneklem oranları belirlenirken büyük eğitim kümesini kullanan deneyler, küçük eğitim seti kullanan deneyler olmak üzere 2 farklı deney grubunda deneyler gerçekleştirilmiştir.

5.3.1. Küçük eğitim kümesi kullanılarak elde edilen sonuçlar

Eğitim seti olarak ilk oturumdaki 100 kişinin yüz ifadesi değişimi olmayan görüntüleri (AR1) kullanılmıştır. Test setinin oluşturulması için eğitim için seçilen kişilerin diğer tüm kategoriler içinde yer alan görüntüleri kullanılmıştır.

Çizelge 5.3'te görüleceği gibi kapanma durumunda en iyi başarı oranları 45x45 alt örneklemede elde edilmiştir (AR8, AR11). Ayrıca yüksek alt örneklemelerde ışıklandırma problemi olan görüntülerde tanıma performansı daha yüksek olabilmektedir. İfade değişimlerinde başarı oranlarında küçük dalgalanmalar olsa da elde edilen sonuçlar birbirine yakındır. Dolayısıyla yüz ifadesi değişimleri için başarı oranının alt örneklem miktarından küçük veri setleri için etkilendiği söylenemez.

Çizelge 5.3. Küçük veri setinde farklı alt örnekleme göre elde edilmiş başarı oranları (%) (İlk oturum)

E: İfade Değişimi, I: Işıklandırma Değişimi, O: Kapanma

AR2: Gülümseme, AR3: Sınırlı, AR4: Bağırma, AR5: Soldan ışık, AR6: Sağdan ışık, AR7: Önden ışık, AR8: Gözlük, AR9: Gözlük ve solda ışık, AR10: Gözlük ve sağdan ışık, AR11: Peçe, AR12: Peçe ve soldan ışık, AR13: Peçe ve sağdan ışık

	E	E	E	I	I	I	O	O+I	O+I	O	O+I	O+I
AÖ Oranı	AR 2	AR 3	AR 4	AR 5	AR 6	AR 7	AR 8	AR 9	AR 10	AR 11	AR 12	AR 13
20x20	100	99	67	98	92	42	97	74	71	88	55	42
25x25	100	100	77	98	92	48	97	78	76	88	60	53
30x30	98	100	78	98	92	55	98	82	76	93	63	57
35x35	100	100	79	98	92	54	98	85	80	91	68	52
40x40	100	100	79	98	95	56	98	82	86	94	71	56
45x45	100	100	78	98	96	61	98	83	83	96	70	63
50x50	100	100	77	98	97	63	98	82	86	94	71	58
55x55	99	100	77	97	96	64	99	81	84	93	70	61
60x60	99	100	78	98	97	61	98	82	83	93	71	62

İkinci oturumun test amacıyla kullanılmasıyla elde edilen başarı oranları Çizelge 5.4'te verilmiştir. İlk oturumdaki 45x45'te kapanma durumlarında tanınmanın en yüksek çıktığı miktarın aksine ikinci oturumda 55x55'te en yüksek değerlere ulaşmaktadır.

Çizelge 5.4. Küçük veri setinde farklı alt örnekleme göre elde edilmiş başarı oranları (%) (İkinci oturum)

E: İfade Değişimi I: Işıklandırma Değişimi O: Kapanma

AR15: Gülümseme AR16: Sınırlı AR17: Bağırma AR18: Soldan ışık
AR19: Sağdan ışık AR20: Önden ışık AR21: Gözlük AR22: Gözlük ve solda ışık AR23: Gözlük ve sağdan ışık AR24: Peçe AR25: Peçe ve soldan ışık AR 26: Peçe ve sağdan ışık

	E	E	E	I	I	I	O	O+I	O+I	O	O+I	O+I
AÖ	AR	AR	AR	AR	AR	AR	AR	AR	AR	AR	AR	AR
Oranı	15	16	17	18	19	20	21	22	23	24	25	26
20x20	72	83	41	77	72	74	72	46	33	53	27	27
25x25	77	90	36	85	73	30	76	49	43	62	36	30
30x30	81	89	38	90	79	38	80	43	42	62	34	32
35x35	82	91	33	92	80	30	76	51	43	66	35	37
40x40	80	90	34	91	80	38	81	50	46	66	36	39
45x45	80	90	34	92	82	40	79	52	44	67	37	44
50x50	83	91	35	92	81	39	78	52	44	65	35	47
55x55	81	89	39	90	80	38	80	52	45	70	36	37
60x60	84	89	34	89	78	40	79	53	45	70	34	42

5.3.2. Büyük eğitim kümesi kullanılarak elde edilen sonuçlar

Geniş eğitim veri seti kullanılarak sonuçları elde etmek için eğitim seti olarak her iki oturumdaki yüz ifadesi değişimi olan 100 (AR1, AR2, AR3, AR4, AR14, AR15, AR16, AR17) kişinin 8'er görüntüsü kullanılmıştır. Hatalı olan W-027-14 görüntüsü eğitimden çıkarıldığında eğitim seti 799 görüntü içerecek şekilde oluşmuştur. Test için her kişinin gözlüklü ve peçeli (AR8, AR21, AR11, AR24) görüntüleri kullanılmış ve her biri 200 görüntü içeren iki farklı test seti oluşturulmuştur. Yapılan deney sonucunda en iyi başarı oranı 40x40 alt örneklemede elde edilmiştir. Deneyde gözlüklüler ile yapılan deneyde %100, peçeliler ile yapılan deneyde %98 başarı oranları elde edilmiştir. Sonuçlar Çizelge 5.5'de paylaşılmıştır.

Çizelge 5.5. Büyük eğitim kümesi kullanılarak elde edilen sonuçlar

Alt Örnekleme	Başarı Oranı (%)	
	Gözlüklü	Peçeli
20x20	97	94
25x25	99,5	96,5
30x30	99,5	95,5
35x35	99	97,5
40x40	100	98
45x45	99,5	96
50x50	100	97
55x55	100	97
60x60	99,5	98

5.3.3. Doğrusal yakınsama tabanlı çalışmalarla benzer deneyler yapılarak elde edilen sonuçlar

İfade değişimlerinde başarı oranının alt örnekleme oranına göre değişimini incelemek için 100 kişinin her iki oturumdaki ifade değişimi olmayan görüntüleri (AR1, AR14) eğitim amacıyla kullanılmıştır. Test seti olarak yine aynı 100 kişinin ifade değişimleri olan (AR2, AR3, AR4, AR15, AR16, AR17) her iki oturumdaki görüntüleri kullanılmıştır. Hatalı olan W-027-14 görüntüsü eğitim setinden çıkarılmıştır. Sonuç olarak 199 eğitim görüntüsü, 600 test görüntüsü seçilmiştir. Bu deney Lai ve Jiang [36] tarafından yapılan çalışmadaki deneyle benzerdir. Yine aynı çalışmada alt örnekleme miktarı olarak 20x28 alınmıştır.

Çizelge 5.6'da elde edilen sonuçlara bakılırsa farklı alt örnekleme oranlarında küçük dalgalanmalar olsa da en iyi başarı oranı %92 olarak 30x30'da elde edilmiştir. Lai ve Jiang [37] çalışmalarında %92,4 başarı oranı elde etmişlerdir.

Çizelge 5.6. Yüz ifadesi değişimi problemine karşı dayanıklılığın incelenmesi için yapılan deneyden elde edilen başarı oranları

Alt Örnekleme Oranı	Başarı Oranı (%)
20x20	91,3
25x25	91,3
30x30	92
35x35	90
40x40	90,7
45x45	90,5
50x50	89,7
55x55	90,3
60x60	89,5

Bölüm 5.3.2’de elde edilen sonuçlar tez çalışmasında geniş veri seti kullanılarak elde edilmiş en iyi sonuçlardır. Yapılan deney alt örnekleme miktarları dışında diğer çalışmalardaki deneylerle yakın sonuçlar vermiştir [35,36,37,39].

Yang ve ark. [37] tarafından yapılan çalışmada yer alan, her iki oturumu da içeren deney için ilk oturumdan 100 kişinin her birinin ifade değişimi olmayan ışıklandırma içeren (AR1, AR5, AR6, AR7) 4 görüntüsü eğitim amacıyla ve her iki oturumda her biri için gözlük, peçe ve ışıklandırma içeren (AR8-AR13, AR21-AR26) 3 görüntüsü test amacıyla kullanılmıştır. Sonuç olarak eğitim seti 400 görüntü, test seti ise her bir oturum için ayrı ayrı olmak üzere 300’erden iki parça olacak şekilde seçilmiştir. Alt örnekleme oranı olarak aynı çalışmada 42x30 alınmıştır. Buradaki deneyde ise 35x35 değeri alınmıştır.

Çizelge 5.7’de gözlük kapanması için daha iyi sonuç elde edilmişken peçe kapanmalarında bu eğitim seti için başarı oranları LRP adımıyla düşmektedir. Bu yüzden ilk sınıflandırıcı frekans değeri 3’e düşürülerek, yani ilk sınıflandırıcı güvenilirliği artırılarak peçeli görüntüler için deney tekrarlanmıştır.

Çizelge 5.7. Geliştirilen yöntemin farklı oturumlar üzerinde denenmesi ile elde edilen başarı oranları (%)

Çalışmalar	Örnek Sayısı	Gözlük Oturum1	Peçe Oturum1	Gözlük Oturum2	Peçe Oturum2
Tez	400	99,3	93	84,7	63,7
RRC_L1 [37]	400	99	93,3	89,3	76,3

Çizelge 5.8 incelendiğinde başarı oranlarında göze çarpar bir yükselme olduğu görülebilmektedir. Ayrıca ilk oturum için başarı oranı RRC_L1'in üzerine çıkmıştır.

Çizelge 5.8. İlk sınıflandırıcı güvenilirliği artırılarak yapılan deney sonucunda elde edilen başarı oranları (%)


Çalışmalar	Örnek Sayısı	Peçe Oturum1	Peçe Oturum2
Tez	400	96,3	72
RRC_L1 [37]	400	93,3	76,3

5.4. Frekans Değerinin Etkinliğinin İncelenmesi

Frekans değerinin etkinliğini incelemek amacıyla ilk oturumda yer alan 100 kişinin ifade değişimi olmayan (AR1) 100 görüntüsü eğitim amacıyla ve aynı kişilerin gözlüklü ve peçeli 100'er görüntüsü test amacıyla kullanılmıştır (AR8, AR11). Deneyler öklit alt sınır değerleri 13 olmak üzere 20x20, 25x25, 30x30, ... , 85x85, 90x90 alt örnekleme miktarlarının her biri için ayrı ayrı yapılmış ve elde edilen başarı oranlarının ortalamalarının frekans eşik değerine göre değişimi Şekil 5.4'deki grafikte verilmiştir.

Şekil 5.4 incelendiğinde en iyi frekans değerinin 5 değeri olduğu görülebilmektedir. 5 değerinden sonra ilk sınıflandırıcı seçimine güven azaldığı için ilk sınıflandırıcının seçebilirliği kaybolmaktadır. Bu sebeple frekans değeri arttıkça ilk sınıflandırıcı

sadece komşuluk seçimi gerçekleştirmekte ve her bir sınıflandırma sonucu LRP sonucuna göre belirlenmektedir. Bu yüzden başarı oranı %93 - %94 arasında bir değere yakınsamaktadır. Frekans değerinin fazla düşürülmesi durumunda ilk sınıflandırıcı daha fazla yanlış karar verdiği için başarı oranı %90 değerine yakınsamaktadır.



Şekil 5.4. Frekans değerinin etkinliği

5.5. Sonuçların Literatür İçi Diğer Çalışmalarla Karşılaştırılması

Elde edilen sonuçlar literatürdeki diğer çalışmalarla karşılaştırılmıştır. Her kişi için bir eğitim görüntüsünün kullanıldığı çalışmalar Çizelge 5.9'da verilmiştir.

Hazırlanan yöntem Çizelge 5.9'da yer alan çalışmalarla karşılaştırıldığında gözlük kapanmalarında [60]'daki çalışmadan daha iyi sonuç üretirken diğer alanlarda daha başarılı değildir. Fakat [60]'daki çalışmada verilmeyen gözlük ve ışıklandırma içeren

kapanmalarda da bu çalışma %83 ve %83 başarı oranlarına ulaşmıştır. Geriye kalan diğer çalışmalara göre başarı oranı bağırma ifadesi hariç ya aynıdır ya da daha iyidir.

Çizelge 5.9. Her kişi için tek eğitim görüntüsü kullanan çalışmaların başarı oranları (%)

E: İfade Değişimi I: Işıklandırma Değişimi O: Kapanma

AR2: Gülümseme, AR3: Sınırlı, AR4: Bağırma, AR5: Soldan ışık, AR6: Sağdan ışık, AR7: Önden ışık, AR8: Gözlük, AR9: Gözlük ve solda ışık, AR10: Gözlük ve sağdan ışık, AR11: Peçe, AR12: Peçe ve soldan ışık, AR13: Peçe ve sağdan ışık

		E	E	E	I	I	I	O	O+I	O+I	O	O+I	O+I
	Örnek Sayısı	AR 2	AR 3	AR 4	AR 5	AR 6	AR 7	AR 8	AR 9	AR 10	AR 11	AR 12	AR 13
[47]	50	94	96	57	-	-	-	80	-	-	82	-	-
[57]	126	96	-	60	96	87	-	90	-	-	85	-	-
[2]	135	96	-	49	84	-	-	84	-	-	87	-	-
[60]	119	100	100	95,80	100	100	98,32	94,96	-	-	99,16	-	-
[21]	100	100	100	88	-	-	-	98	-	-	90	-	-
[63]	100	-	-	-	-	-	-	88	-	-	96	-	-
Tez	100	100	100	78	98	96	61	98	83	83	96	70	63

Bölüm 5.3.2'deki deneyi uygulayan çalışmalarla bu çalışmanın karşılaştırılması Çizelge 5.10'da verilmiştir. Çizelge 5.10 incelendiğinde bu çalışmanın diğer çalışmalardan daha iyi sonuç ürettiği görülebilmektedir. İfade değişimlerinin karşılaştırılması için Lai ve Jiang [36] tarafından yapılan aynı deney tekrarlanmış ve %92 başarı oranıyla yaklaşık bir tanıma oranı sağlanmıştır (Çizelge 5.6). Işıklandırma ve kapanma içeren görüntülerle yapılan deneyde değişik parametrelerde ilk oturum için [38]'deki çalışmada elde edilen başarılarından daha iyisi elde edilmiştir (Çizelge 5.7, Çizelge 5.8). Fakat ilk oturumun eğitim ve ikinci oturumun test amacıyla kullanıldığı deneylerde zaman faktörünün etkilerinden dolayı yeterince başarılı sonuçlar elde edilememiştir.

Çizelge 5.10. Doğrusal yakınsama tabanlı çalışmaların başarı oranları (%)

Sınıflandırma Aşaması	Örnek Sayısı	Gözlük	Peçe
Wright, 2009 [35]	799	97,5	93,5
Li, 2011 [39]	952	96,6	97,5
Lai, 2012 [36]	799	100	97,5
Yang, 2013 [37]	799	100	97,5
Tez	799	100	98

6. SONUÇLAR VE ÖNERİLER

Bu çalışmada yüz tanıma sistemlerinde kapanma problemi kapsamındaki çalışmalar incelenmiştir. Bu çalışmaların bazılarında kapanmaların onarılması benimsenmiş, bazılarında kapanmaların tespit edilip temiz pikseller kullanılarak tanıma işlemi yapılması benimsenmiştir. Onarma metotları bu alanda yeterince başarılı olamamaktadır. Bunun yanında temiz piksellerde tanıma yapan çalışmalarda yüksek başarı oranları elde edilebilmektedir.

Kapanmaların tespiti iki şekilde yapılabilmektedir. Bunlardan ilkinde kapanma bilgisinin önceden bilindiği kabul edilir. Fakat böyle bir kabulün pratikte uygulanabilirliği düşüktür. İkinci yaklaşım çeşitli tekniklerle kapanma olan kısmın bulunmasına dayanır. Fakat kapanmalar çok çeşitli şekillerde ve renklerde olabilmektedir. Kontrollü bir ortamda renk bazlı yapılan kapanma bulma işlemleri de bu yüzden pratikte uygulanabilirliği düşüktür, çünkü kapanmaların güneş gözlüğü gibi siyah renkli olduğu AR veri tabanında bu gibi çalışmalar iyi sonuç verirken kapanmanın ten rengine yakın olduğu durumlarda kapanmaların bulunması zor hale gelecektir. Ayrıca kapanma tespiti yapan çalışmalarda bu işlem için ayrıca bir işlem maliyeti ortaya çıkmaktadır çünkü bu işlem için ek bir öznitelik çıkarımı, sınıflandırma işlemi veya piksel bazlı bazı işlemler gerekebilmektedir. Bu tez çalışmasında eğitim seti için öklit haritasının bir kere hesaplanıp saklanması yeterlidir. Tanıma işlemi sırasında haritanın eğitim seti için tekrar tekrar hesaplanmasına gerek yoktur.

Yapılan çalışmada yukarıda belirtilen problemlerden dolayı değişim mantığına dayanan öklit haritası yöntemi geliştirilmiştir. Bu yöntemle kapanmaların renginin tanıma işlemi için bir önemi kalmamaktadır. Ayrıca değişimlerin seçilip kuvvetlendirildiği bu yöntemde parçalı bir teknik kullanılarak ve LRP tekniğiyle kapanma problemi çift aşamalı bir tahmin algoritmasıyla çözülmeye çalışılmıştır. Çalışmada her kişi için tek eğitim görüntüsünün kullanıldığı deneylerde gözlüklülerde %98, peçelilerde %96 ve her bir kişi için birden fazla eğitim görüntüsü

kullanılan deneylerde gözlüklülerde %100 ve peçelilerde %98 başarı oranları ile başarılı sonuçlar elde edilmiştir.

Literatürde yapılan çalışmalarda herbir kişi için tek eğitim görüntüsü kullanılarak yüksek başarı elde edilmesi ayrı bir alan olarak algılanmaktadır, çünkü pratikte her bir kişi için çok fazla görüntü elde bulundurulması zordur. Tek eğitim görüntüsü durumunda geliştirilen algoritma birçok çalışmadan daha iyi sonuçlar vermektedir. Li ve ark. [60] tarafından yapılan çalışma ile karşılaştırıldığında gözlük kapanmasında daha iyi bir başarı oranı elde edilmesine rağmen diğer veri setlerinde daha başarılı değildir (Çizelge 5.9).

Doğrusal yakınsama sınıflandırıcıları literatürde genellikle aynı sınıfa ait birçok örnek kullanılarak test edilirken bu çalışmada sınıf başına tek örnek kullanılması durumunda dahi başarı oranına katkı sağlamıştır.

Tez çalışması doğrusal yakınsama tabanlı yöntemler ile benzer şartlarda karşılaştırıldığında yakın başarı oranları yakalanmaktadır (Çizelge 5.10). Bu çalışmalarda test için kullanılan eğitim kümesi ile bu çalışmada kullanılan eğitim kümesi benzerdir. Fakat başarıların elde edildiği alt örnekleme miktarları farklıdır.

Geliştirilen algoritma kapanmalarda iyi sonuçlar vermesine rağmen oturum farklılıklarında aynı başarıyı gösterememektedir. Bunun sebebi olarak iki oturum arasındaki poz farklılıkları, kilo farklılıkları vb. zamana bağlı defarmasyonlar gösterilebilir. Sonraki çalışmalarda bu konunun araştırılmasında yarar vardır.

Işık probleminde ışığın aşırı derecede yüksek olması yüzdeki değişimleri azaltmakta ve tanıma performansını düşürmektedir. Bu problemin çözümü için öklit haritası işleminden önce bir ön işleme metodu geliştirilebilir. Bazı yüz ifadelerinde algoritma başarılı olsa da bağırma gibi tüm yüz üzerinde değişime neden olan durumlarda tatmin edici bir başarı oranı elde edilememektedir.

KAYNAKLAR

1. Ekenel, H.K., Stiefelhagen, R., "Why is Facial Occlusion a Challenging Problem?", *Advances in Biometrics*, 5558:299-308 (2009).
2. Oh, H.J., Lee, K.M., Lee, S.U., "Occlusion invariant face recognition using selective local non-negative matrix factorization basis images", *Image and Vision Computing*, 26(11):1515 - 1523 (2008).
3. Faaya, T.H., Toygar, Ö., "Recognizing Faces under Facial Expression Variations and Partial Occlusions", *7th WSEAS International Conference on Signal Processing (SIP'08)*, 37 - 42 (2008).
4. Rama, A., Tarres, F., Goldmann, L., Sikora, T., "More robust face recognition by considering occlusion information", *IEEE International Conference on Automatic Face & Gesture Recognition*, 1-6 (2008).
5. Toygar, Ö., "Sensitivity Analysis of Partitioning-based Face Recognition Algorithms on Occlusions", *6th WSEAS International Conference*, 21 - 27 (2007).
6. Rama, A., Tarres, F., "Lophoscopic Pca: A Novel Method For Face Recognition", *Workshop on Image Analysis for Multimedia Interactive Services*, (2005).
7. Shermina, J., Vasudevan, V., "Face Recognition System with various Expression and Occlusion based on a Novel Block Matching Algorithm and PCA", *International Journal of Computer Applications*, 38(11): 0975-8887 (2012).
8. Lanitis, A., "Person Identification From Heavily Occluded Face Images", *SAC '04 Proceedings of the 2004 ACM symposium*, 5-9 (2004).
9. Faaya, T.H. , Toygar, Ö., "Illumination Invariant Face Recognition under Various Facial Expressions and Occlusions", *Image and Signal Processing*, 5099:304-311 (2008).
10. Zuo, W., Wang, K., Zhang, D., "Robust Recognition of Noisy and Partially Occluded Faces Using Iteratively Reweighted Fitting of Eigenfaces", *Advances in Multimedia Information Processing - PCM 2006*, 4261:844-851 (2006).
11. Kanan, H.R., Moin, M.S., "Recognizing Partially Occluded Faces from a Single Exemplar Image Per Person", *Advances in Information Security and Assurance*, 5576:100-109 (2009).
12. Chen, Z., Xu, T., Han, Z., "Occluded face recognition based on the improved SVM and block weighted LBP", *IEEE 2011 International Conference on Image Analysis and Signal Processing (IASP)*, , 118-122 (2011).

13. Zeng, J.Y., Gan, J.Y., Zhai, Y.K., “A novel partially occluded face recognition method based on biomimetic pattern recognition”, **2012 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)**, 175-179 (2012).
14. Liu, J., Chen, S., Tan, X., “Fractional order singular value decomposition representation for face Recognition”, **Pattern Recognition**, 41(1):378-395 (2008).
15. Zhu, Y., Liu, J., Chen, S., “Semi-random subspace method for face recognition”, **Image and Vision Computing**, 27(9):1358-1370 (2009).
16. Kim, J., Choi, J., Yi, J., Turk, M., “Effective Representation Using ICA for Face Recognition Robust to Local Distortion and Partial Occlusion”, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 27(12):1977-1981 (2005).
17. De Souza, A.F., Badue, C., Pedroni, F., Oliveira, E., Dias, S.S., Oliveira, H., de Souza, S.F., “Face Recognition with VG-RAM Weightless Neural Networks”, **Artificial Neural Networks - ICANN 2008**, 5163:951-960 (2008).
18. Lin, J., Ming, J., Crookes, D., ”Robust face recognition using posterior union model based neural networks” , **Computer Vision**, 3(3):130-142 (2009).
19. Lin, J., Ming, J., Crookes, D., “Robust face recognition with partially occluded images based on a single or a small number of training samples”, **2009. ICASSP 2009. IEEE International Conference on Acoustics, Speech and Signal Processing**, 881-884 (2009).
20. Lin, J., Ming, J., Crookes, D., “A probabilistic union approach to robust face recognition with partial distortion and occlusion”, **2008. ICASSP 2008. IEEE International Conference on Acoustics, Speech and Signal Processing**, 993-996 (2008).
21. Tan, X., Chen, S., Zhou, Z.H., Liu, J., “Face Recognition Under Occlusions and Variant Expressions with Partial Similarity”, **IEEE Transactions on Information Forensics and Security**, 4(2):217-230 (2009).
22. Tan, X., Chen, S., Zhou, Z.H., Zhang, F., “Recognizing Partially Occluded, Expression Variant Faces from Single Training Image per Person with SOM and soft kNN Ensemble”, **IEEE Transactions on Neural Networks**, 16(4):875-886 (2005).
23. Shin, J.H. , Smith, D., Swiercz, W., Staley, K., Rickard, J., Montero, J., Kurgan, L.A., Cios, K.J., “Recognition of Partially Occluded and Rotated Images With a Network of Spiking Neurons”, **IEEE Transactions on Neural Networks**, 21(11):1697-1709 (2010).

24. Zana, Y., Cesar, R.M., de A. Barbosa, R., "Automatic Face Recognition System Based on Local Fourier-Bessel Features", *18th Brazilian Symposium on Computer Graphics and Image Processing, SIBGRAPI 2005*, 233-240 (2005).
25. Štruc, V., Pavešić, N., "The Complete Gabor-Fisher for Robust Face Recognition", *EURASIP Journal on Advances in Signal Processing*, 1-26 (2010).
26. Kanan, H.R., Faez, K., "Adaptively Weighted Sub-Gabor Array for Single Model-Based Human Face Recognition", *Iranian Journal of Electrical and Computer Engineering*, 9(1):1-12 (2010).
27. Zhang, W., Shan, S., Gao, W., Chen, X., Zhang, H., "Local Gabor Binary Pattern Histogram Sequence (LGBPHS): A Novel Non-Statistical Model for Face Representation and Recognition", *2005. ICCV 2005. Tenth IEEE International Conference on Computer Vision*, 786-791 (2005).
28. Zana, Y., Cesar, R.M., Feris, R., Turk, M., "Local approach for face verification in polar frequency domain", *Image and Vision Computing*, 24(8):904-913 (2006).
29. Kanan, H.R., Faez K., "Recognizing faces using Adaptively Weighted Sub-Gabor Array from a single sample image per enrolled subject", *Image and Vision Computing*, 28(3):438-448 (2010).
30. Olivares-Mercado, J., Hotta, K., Takahashi, H., Perez-Meana, H., Miyatake, M.N., Sanchez-Perez, G., "Face Recognition Based on Normalization and the Phase Spectrum of the Local Part of an Image", *Advances in Visual Computing*, 5359:278-286 (2008).
31. Liu, L., Sun, Y., Yin, B., Song, C., "A Novel Nonuniform Division Strategy for Wearing Eyeglasses Face Recognition", *2009. ICIG '09. Fifth International Conference on Image and Graphics*, 907-911 (2009).
32. Min, R., Hadid, A., Dugelay, J., "Improving the Recognition of Faces Occluded by Facial Accessories", *2011 IEEE International Conference on Automatic Face & Gesture Recognition and Workshops (FG 2011)*, 442-447 (2011).
33. Zhang, W., Shan, S., Chen, X., Gao, W., "Local Gabor Binary Patterns Based on Kullback-Leibler Divergence for Partially Occluded Face Recognition", *Signal Processing Letters*, 14(11):875-878 (2007).
34. Huang, S.M., Yang, J.F., "Robust Face Recognition under Different Facial Expressions, Illumination Variations and Partial Occlusions", *Advances in Multimedia Modeling*, 6524:326-336 (2011).

35. Wright, J., Yang, A.Y., Ganesh, A., Sastry, S.S., Ma, Y., "Robust face recognition via sparse representation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2):210-227 (2009).
36. Lai, J., Jiang, X.. "Modular Weighted Global Sparse Representation for Robust Face Recognition", *Signal Processing Letters*, 19(9):571-574 (2012).
37. Yang M., Zhang, L., Yang, J., Zhang D., "Regularized Robust Coding for Face Recognition", *IEEE Transactions on Biometrics Compendium*, 22(5):1753-1766 (2013).
38. Wei, X., Li, C.T., Hu, Y., "Robust Face Recognition under Varying Illumination and Occlusion Considering Structured Sparsity", *2012 International Conference on Digital Image Computing Techniques and Applications (DICTA)*, 1-7 (2012).
39. Li, X.X., Dai, D.Q., Zhang, X.F., Ren, C.X., "Face Recognition with Continuous Occlusion Using Partially Iteratively Reweighted Sparse Coding", *IEEE 2011 First Asian Conference on Pattern Recognition (ACPR)*, 293-297 (2011).
40. Zhou, Z., Wagner, A., Mobahi, H., Wright, J., Ma, Y., "Face Recognition With Contiguous Occlusion Using Markov Random Fields", *IEEE 12th International Conference on Computer Vision*, 1050-1057 (2009).
41. Yi, D., Li, S.Z., "Learning Sparse Feature for Eyeglasses Problem in Face Recognition", *IEEE International Conference on Automatic Face & Gesture Recognition and Workshops (FG 2011)*, 430-435 (2011).
42. He, R., Zheng, W.S., Hu, B.G., Kong, X.W., "A Regularized Correntropy Framework for Robust Pattern Recognition", *Neural Computation*, 23(8):2074-2100 (2011).
43. Jia, H., Martinez, A.M., "Face Recognition with Occlusions in the Traing and Testing Sets", *2008. FG '08. 8th IEEE International Conference on Automatic Face & Gesture Recognition*, 1-6 (2008).
44. Deng, Y., Dai, Q., Zhang, Z., "Graph Laplace for Occluded Face Completion and Recognition", *IEEE Transactions on Image Processing*, 20(8):2329-2338 (2011).
45. Jia, H., Martinez, A.M., "Support Vector Machines in Face Recognition with Occlusions", *IEEE Conference on Computer Vision and Pattern Recognition*, 136-141 (2009).
46. Naseem, I., Togneri, R., Bennamoun, M., "Linear Regression for Face Recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(11):2106-2112 (2010).

47. Martinez, A.M., "Recognition imprecisely localized, partially occluded, and expression variant faces from a single sample per class", *IEEE Trans. Pattern Anal. Mach. Intell.*, 24(6):748-763 (2002).
48. Pappachen James, A., Dimitrijevic, S., "Inter-image outliers and their application to image classification", *Pattern Recognition*, 43(12):4101-4112 (2010).
49. Fransens, R., Strecha, C., Van Gool, L., "A Mean Field EM-algorithm for Coherent Occlusion Handling in MAP-Estimation Problems", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 300-307 (2006).
50. Lee, P.H., Wang, Y.W., Yang, M.H., Hsu, J., Hung, Y.P., "Distinctive Personal Traits for Face Recognition Under Occlusion", *IEEE International Conference on Systems*, 4202-4207 (2006).
51. Huang, S.M., Yang, J.F., Chang, S.C., "Robust face recognition using subface hidden Markov models", *Proceedings of 2010 IEEE International Symposium on Circuits and Systems (ISCAS)*, 1547-1550 (2010).
52. Yuan, C., Neubauer, C., "A Variational Bayesian Approach for Classification with Corrupted Inputs", *IEEE Conference on Computer Vision and Pattern Recognition*, 1-8 (2007).
53. Venkat, I., Khader, A.T., Subramanian, K.G., De Wilde, P., "Recognizing occluded faces by exploiting psychophysically inspired similarity maps", *Pattern Recognition Letters*, 34(8):903-911 (2013).
54. Fransens, R., Strecha, C., Van Gool, L., "Robust Estimation in the Presence of Spatially Coherent Outliers", *CVPRW '06. Conference on Computer Vision and Pattern Recognition Workshop*, 102 (2006).
55. Hotta, K., "Robust face recognition under partial occlusion based on support vector machine with local Gaussian summation kernel", *Image and Vision Computing*, 26(11):1490-1498 (2008).
56. Lai, H., Ramanathan, V., Wechsler, Y., "Reliable face recognition using adaptive and robust correlation filters", *Computer Vision and Image Understanding*, 111(3):329-350 (2008).
57. De Marsico, M., Nappi, M., Ricco, D., "FARO: FAcE Recognition Against Occlusions and Expressions Variations", *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 40(1):121-132 (2010).
58. Abate, A.F., Nappi, M., Riccio, D., Tucci, M., "Occluded Face Recognition by Means of the IFS", *Image Analysis and Recognition*, 3656:1073-1080 (2005).

59. Abate, A.F., Nappi, M., Riccio, D., Tortora, G., "RBS: A Robust Bimodal System For Face Recognition", *World Scientific International Journal of Software Engineering and Knowledge Engineering*, 17(04):497-513 (2007).
60. Li, Z., Imai, J., Kaneko, M., "Robust Face Recognition Using Block-based Bag of Words", *2010 20th International Conference on Pattern Recognition (ICPR)*, 1285-1288 (2010).
61. Kisku, D.R., Tistarelli, M., Sing, J.K., Gupta, P., "Face Recognition by Fusion of Local and Global Matching Scores using DS Theory: An Evaluation with Uni-classifier and Multi-classifier Paradigm", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 60-65 (2009).
62. Liu, N., Lai, J., Qiu, H., "Robust Face Recognition by Sparse Local Features from a Single Image under Occlusion", *Sixth International Conference on Image and Graphics (ICIG)*, 500-505 (2011).
63. Chen, W., Gao, Y., "Recognizing Partially Occluded Faces from a Single Sample Per Class Using String-Based Matching", *Computer Vision – ECCV 2010 Lecture Notes in Computer Science*, 6313:496-509 (2010).
64. Park, B.G., Lee, K.M., Lee, S.U., "Face Recognition Using Face-Arg Matching", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(12):1982-1988 (2005).
65. Kanan, H.R., Faez, K., Gao, Y., "Face recognition using adaptively weighted patch PZM array from a single exemplar image per person", *Pattern Recognition*, 41(12):3799-3812 (2008).
66. Zeng, Z., Fang, T., Shah, S., Kakadiaris, I.A., "Local Feature Hashing for Face Recognition", *2009. BTAS '09. IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems*, 1-8 (2009).
67. Li, Q., Ye, J., Li, M., Kambhamettu, C., "Adaptive Appearance Based Face Recognition", *World Scientific Int. J. Artif. Intell. Tools*, 17(01):175-193 (2008).
68. Alyuz, N., Gokberk, B., Spreeuwens, L., Veldhuis, R., Akarun, L., "Robust 3D Face Recognition in the Presence of Realistic Occlusions", *2012 5th IAPR International Conference on Biometrics (ICB)*, 111-118 (2012).
69. Colombo, A., Cusano, C., Schettini, R., "Occlusions in Face Recognition: a 3D Approach", *State of the Art in Face Recognition*, 250 (2009).

70. Colombo, A., Cusano, C., Schettini, R., "Recognizing Faces In 3D Images Even In Presence Of Occlusions", **2008. BTAS 2008. 2nd IEEE International Conference on Biometrics: Theory, Applications and Systems**, 1-6 (2008).
71. Alyüz, N., Gökberk, B., Akarun, L., "A 3D Face Recognition System for Expression and Occlusion Invariance", **Biometrics: Theory, Applications and Systems, 2008. BTAS 2008. 2nd IEEE International Conference**, 1-7 (2008).
72. Colombo, A., Cusano, C., Schettini, R., "Face³ a 2D+3D Robust Face Recognition System", **2007. ICIAP 2007. 14th International Conference on Image Analysis and Processing**, 393-398 (2007).
73. Alyuz, N., Gokberk, B., Spreuwers, L., Veldhuis, R., Akarun, L., "Occlusion-robust 3D face recognition using restoration and local classifiers", **2011 IEEE 19th Conference on Signal Processing and Communications Applications (SIU)**, 750- 753 (2011).
74. Turk, M., Pentland, A., "Face recognition using eigenfaces", **Proceedings of IEEE Conference on Computer Vision and Pattern Recognition**, Maui, Hawaii, 586-591 (1991).
75. Comon, P., "Independent component analysis", **Signal Processing**, 36:287-314 (1994).
76. Martinez, A.M., Kak, A.C., "PCA versus LDA.", **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 23(2):228-233 (2001).
77. Koç, M., "New Subspace Approaches in Pattern Recognition", Doktora Tezi, **Anadolu Üniversitesi Fen Bilimleri Enstitüsü**, Eskişehir, (2012).
78. Khurshed, E.S., "Yüz Tanımada Aydınlanmanın Etkisinin Uyarlanırlı Histogram Eşitleme ile Azaltılması", Yüksek Lisans Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, Ankara, (2009).
79. Abate, A.F., Nappi, M., Riccio, D., Sabatino, G., "2D and 3D face recognition: A survey", **Pattern Recognition Letters**, 28(14):1885-1906 (2007).
80. Kim, S.J., Koh, K., Lustig, M., Boyd, S., Gorinevsky, D., "An Interior-Point Method for Large-Scale ℓ_1 -Regularized Least Squares", **IEEE Journal on Selected Topics in Signal Processing**, 1(4):606-617 (2007).
81. İnternet: <http://cvxr.com/cvx/> , (2013).
82. Asif, M.S., Romberg, J., "Fast and Accurate Algorithms for Re-Weighted ℓ_1 -Norm Minimization", **IEEE Transactions on Signal Processing**, 1 (2013).

83. Yang, A.Y., Zhou, Z., Balasubramanian, A.G., Sastry, S.S., Ma, Y. “Fast l_1 -minimization algorithms for robust face recognition”, *IEEE Transactions on Image Processing*, 22(8):3234-3246 (2013).
84. Internet: http://www.stanford.edu/~boyd/l1_ls/ , (2013).
85. Internet: <http://users.ece.gatech.edu/~sasif/homotopy/> , (2013).
86. Internet: <http://www.eecs.berkeley.edu/~yang/software/l1benchmark/> , (2013).
87. Martinez, A.M., Benavente, R., “The AR Face Database”, **CVC Technical Report #24**, (1998).

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : YOLCU, Veli Yigit
Uyruğu : T.C.
Doğum tarihi ve yeri : 12.05.1988 İzmir
Medeni hali : Bekar
e-mail : vyigity@hotmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	Gazi Üniversitesi/ Bilgisayar Müh.	2010
Lise	75. Yıl Milli Piyango Anadolu Lisesi	2006

İş Deneyimi

Yıl	Yer	Görev
2010-2010	BMBSOFT Yazılım Ltd. Şti.	Yazılım Müh.
2011-	Türkiye Kalkınma Bankası A.Ş.	Uzman Yrd.

Yabancı Dil

İngilizce

Hobiler

Bilgisayar teknolojileri