



BİLECİK ŞEYH EDEBALI
ÜNİVERSİTESİ

**BİLECİK
ŞEYH EDEBALI ÜNİVERSİTESİ**

**Fen Bilimleri Enstitüsü
Enerji Sistemleri Mühendisliği Ana Bilim Dalı**

**YÜZ BÖLGELERİNİN AĞIRLIKLANDIRILMASININ YEREL
İKİLİ ÖRÜNTÜLER İLE YÜZ TANIMA PERFORMANSINA
ETKİSİ**

**ŞULENUR EROL
Yüksek Lisans Tezi**

**Tez Danışmanı
Dr. Öğr. Üyesi MEHMET KOÇ**

**BİLECİK, 2019
Ref. No: 10293751**



BİLECİK ŞEYH EDEBALI
ÜNİVERSİTESİ

**BİLECİK
ŞEYH EDEBALI ÜNİVERSİTESİ**

**Fen Bilimleri Enstitüsü
Enerji Sistemleri Mühendisliği Ana Bilim Dalı**

**YÜZ BÖLGELERİNİN AĞIRLIKLANDIRILMASININ YEREL
İKİLİ ÖRÜNTÜLER İLE YÜZ TANIMA PERFORMANSINA
ETKİSİ**

**ŞULENUR EROL
Yüksek Lisans Tezi**

**Tez Danışmanı
Dr. Öğr. Üyesi MEHMET KOÇ**

BİLECİK, 2019



BİLECİK ŞEYH EDEBALI
ÜNİVERSİTESİ

BİLECİK

SEYH EDEBALI UNIVERSITY

**Graduate School of Sciences
Department of Energy Systems Engineering**

**THE EFFECT OF FACE REGIONS' WEIGHTING TO FACE
RECOGNITION PERFORMANCE WITH LOCAL BINARY
PATTERNS**

**ŞULENUR EROL
Master Thesis**

Thesis Advisor

**Asst. Prof. MEHMET KOÇ
BİLECİK, 2019**



BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS
JÜRİ ONAY FORMU

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun 31/07/2019 tarih ve 41-19 sayılı kararıyla oluşturulan jüri tarafından 23/07/2019 tarihinde tez savunma sınavı yapılan Şulenur EROL'un "Yüz Bölgelerinin Ağırlıklandırılmasının Yerel İkili Örüntüler İle Yüz Tanıma Performansına Etkisi" başlıklı tez çalışması Enerji Sistemleri Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS tezi olarak oy birliği/ oy çokluğu ile kabul edilmiştir

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Dr. Öğr. Üyesi Mehmet KOÇ

ÜYE : Doç. Dr. Tolga YÜKSEL

ÜYE : Dr. Öğr. Üyesi Murat BAŞARAN

ONAY

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun
.../.../..... tarih ve/..... sayılı kararı.

İMZA/ MÜHÜR

TEŐEKKÜR

Bu tez alıőmasında bana fikir veren, her zaman yardımcı olan ve yol gösteren, karőılaőtıđım problemlerde özüm önerilerinde bulunan, tavsiye ve yönlendirmeleri ile en iyi őekilde tezi hazırlamama yardımcı olan tez danıőmanım Sayın Dr. Öğr. Üyesi Mehmet KOÇ' a teőekkür ederim.

Tüm hayatım boyunca olduđu gibi bu alıőmam süresince de benden desteklerini esirgemeyen deđerli aileme, tez yazım sürecimde yanımda olup bana anlayıő gösteren sevgilim eőim Ođuzhan EROL'a teőekkür ederim.

BEYANNAME

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kılavuzu'na uygun olarak hazırladığım bu tez çalışmasında, tez içindeki tüm verileri akademik kurallar çerçevesinde elde ettiğimi, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun olarak sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu Üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

...../...../ 2019

Şulenur EROL

YÜZ BÖLGELERİNİN AĞIRLIKLANDIRILMASININ YEREL İKİLİ ÖRÜNTÜLER İLE YÜZ TANIMA PERFORMANSINA ETKİSİ

ÖZET

Yerel İkili Örüntüler (Local Binary Patterns - LBP), yüz, doku, cinsiyet tanıma gibi örüntü tanıma problemlerinde kullanılan başarılı bir öznitelik çıkarım yöntemidir. LBP imgedeki her piksel ile komşu piksellerin gri seviye değerlerini karşılaştırarak öznitelik çıkarımı yapar.

Yüzdeki göz, burun, ağız gibi bazı bölgelerin diğer bölgelere göre sınıflandırma başarımına katkısının daha fazla olduğu bilinmektedir. Bundan dolayı, yüz imgesi dikdörtgensel bölgelere ayrılmıştır. Her bölge için LBP histogramlarının oluşturulmasıyla yerel öznitelikler elde edilmiştir. Yerel öznitelik vektörlerine ait oldukları bölgelerin önem derecelerine göre ağırlıklar verilerek tanıma başarımının artması hedeflenmiştir. Yöntemin başarımını belirlemek için yapılan deneysel çalışmalarda AR ve Genişletilmiş Yale yüz Veri Tabanı B kullanılmıştır. Sınıflandırma aşamasında alt uzay tabanlı Doğrusal Regresyon Sınıflandırıcısı (LRC) ve Ki-kare (χ^2) istatistiği kullanılmıştır.

Yapılan deneyler sonucunda, LRC sınıflandırıcısı başarımının kullanılan veri tabanına göre değişkenlik gösterdiği, ancak χ^2 istatistiğinin kullanılan veritabanından bağımsız olarak yüksek sınıflandırma başarımı sağladığı gözlemlenmiştir.

Anahtar Kelimeler: Yüz Tanıma, Yerel İkili Örüntüler, Regresyon Analizi, Ki-Kare, Sınıflandırma, Ağırlıklandırma

THE EFFECT OF FACE REGIONS' WEIGHTING TO FACE RECOGNITION PERFORMANCE WITH LOCAL BINARY PATTERNS

ABSTRACT

Local Binary Patterns (LBP) is a successful feature extraction method used in pattern recognition problems such as face, texture, and gender recognition. LBP extracts features by comparing the gray level values of each pixel in the image and its neighboring pixels.

It is known that some parts of the face such as eyes, nose and mouth contribute more to the classification performance than other regions. Therefore, the face image is divided into rectangular regions. Local features are obtained by generating LBP histograms for each region. It is aimed increase the classification performance by setting the weights to the local features according to the importance of the corresponding region. In the experimental studies, AR and Expanded Yale face Database B are used to determine the performance of the method. In the classification stage, the subspace-based Linear Regression Classifier (LRC) and the Chi-square (χ^2) statistics are used.

As a result of the experimental studies, it is observed that the performance of the LRC classifier varies according to the database used, but χ^2 statistics achieves high classification performance independent of the database used.

Key Words: Face Recognition, Local Binary Patterns, Regression Analysis, Chi-Square, Classification, Weighting

İÇİNDEKİLER

	Sayfa No
TEŞEKKÜR	
BEYANNAME	
ÖZET	I
ABSTRACT	II
ŞEKİLLER DİZİNİ	IV
ÇİZELGELER DİZİNİ	IV
SİMGELER ve KISALTMALAR DİZİNİ	VI
1.GİRİŞ	1
1.1-Biyometrik Tanıma Sistemleri	1
1.2- Yüz Tanıma.....	3
2.YEREL İKİLİ ÖRÜNTÜLER	6
2.1-Yüzden LBP Kodlarının Elde Edilmesi	8
2.2-Ağırlıklandırma	10
3.SINIFLANDIRICILAR	12
3.1-Regresyon Analizi.....	12
3.2-Ki Kare İstatistiği (χ^2)	14
4.DENEYSEL ÇALIŞMALAR	15
4.1-Veri Tabanları	15
4.1.1- AR Veri Tabanı	15
4.1.2-Genişletilmiş Yale Yüz Veri tabanı B.....	16
4.2-AR Veri Tabanındaki Deneyler	17
4.3- Genişletilmiş Yale Yüz Veri Tabanı B'deki Deneyler	22
5.SONUÇLAR ve YORUMLAR	25
KAYNAKLAR	27
ÖZ GEÇMİŞ	

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 1.1. Genel biyometrik tanıma sisteminin adımları	1
Şekil 1.2. Biyometrik tanıma sistemleri.....	2
Şekil 1.3. Yüz tanımanın aşamaları	4
Şekil 2.1. LBP operatörünün hesaplanması	6
Şekil 2.2. P örnek sayısı ve R simetrik dairesel yarıçap çeşitleri	7
Şekil 2.3. 3×3, 5×5 Ve 7×7'ye bölünmüş yüz görüntüleri	9
Şekil 2.4. 5×5 bölgeye ayrılmış görüntüde histogramlar.....	9
Şekil 2.5. 59×25=1475 boyutlu uçuca eklemiş histogram.....	9
Şekil 2.6. 5x5 'e bölünen yüz görüntüsü, (B) Bölünmüş resme her bölge için uyguladığımız ağırlıklar. Siyah kare 0, koyu gri 1, açık gri 2, beyaz 4 ü temsil etmektedir. (C) Ağırlık verilen resmin görünümü.....	10
Şekil 4.1. Ar yüz veri tabanında bir kişinin ilk oturumdan edilen görüntüleri	15
Şekil 4.2. Ar yüz veri tabanında bir kişinin ikinci oturumdan edilen görüntüleri	16
Şekil 4.3. Genişletilmiş Yale Yüz Veri Tabanında bir kişinin görüntüleri.....	16
Şekil 4.4. Ar veri tabanında deney yapılan görüntünün 5x5 bölgeye ayrılmış Görüntü (solda), kullanılan ağırlık matrisi (ortada), koyu renkler bölgenin düşük öneme sahip olduğunu göstermektedir (sağda).	17
Şekil 4.5. ULBP(8,1) öznelik çıkarımı uLBP(16,2)öznelik çıkarımının grafiksel karşılaştırması.....	21
Şekil 4.6. Yale B Veri Tabanında deney yaptığımız görüntünün 10x10 bölgeye ayrılıp ağırlıklandırılmış görüntüsü.	23

ÇİZELGELER DİZİNİ

	Sayfa No
Çizelge 4.1. Ar veri tabanında $5 \times 5 = 25$ bölgeye ayrılıp tekdüze $uLBP(8,1)$ öznitelik çıkarımı uygulanan deneysel çalışmalar.....	18
Çizelge 4.2. Ar veri tabanında $5 \times 5 = 25$ bölgeye ayrılıp $LBP(8,1)$ öznitelik çıkarımı uygulanan deneysel çalışmalar.....	19
Çizelge 4.3. Eğitim aşamasında seçilen görüntüler ile yapılan deney sonuçları.	20
Çizelge 4.4. Ar veri tabanında $5 \times 5 = 25$ bölgeye ayrılıp $uLBP(16,2)$ öznitelik çıkarımı uygulanan deneysel çalışmalar.	20
Çizelge 4.5. Ar veri tabanında LRC yöntemi ile yapılan deney sonuçları.	22
Çizelge 4.6. Yale B Veri Tabanında $10 \times 10 = 100$ bölgeye ayrılıp $uLBP(8,1)$ öznitelik çıkarımı uygulanan deneysel çalışmalar.....	24
Çizelge 4.7. Yale B Veri Tabanında filtre uygulanmış $10 \times 10 = 100$ bölgeye ayrılıp $uLBP(8,1)$ öznitelik çıkarımı uygulanan deneysel çalışmalar.	24

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

χ^2 : Ki-Kare

σ^2 : Varyans

Kısaltmalar

DCT : Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform)

ICA : Bağımsız Bileşen Analizi (Independent Component Analysis)

LBP : Yerel İkili Örüntüler (Local Binary Patterns)

LDA : Doğrusal Ayırtaç Analizi (Linear Discriminant Analysis)

LRC : Doğrusal Regresyon Sınıflandırıcı (Linear Regression Classifier)


PCA : Temel Bileşen Analizi (Principal Component Analysis)

1.GİRİŞ

1.1-Biyometrik Tanıma Sistemleri

Biyometri, bireyin biyolojik verilerini analiz ederek kimliğini doğrulama bilimidir. Biyometrik sistem; bireyin fizyolojik yada davranışsal özelliklerini tarayarak daha önce oluşturulmuş olan kayıt ile karşılaştırır. Biyometrik tanıma sistemleri kişiye özgü oldukları için güvenlidirler.

Tipik bir biyometrik tanıma sistemi Şekil 1.1 de gösterilen adımları içermektedir.

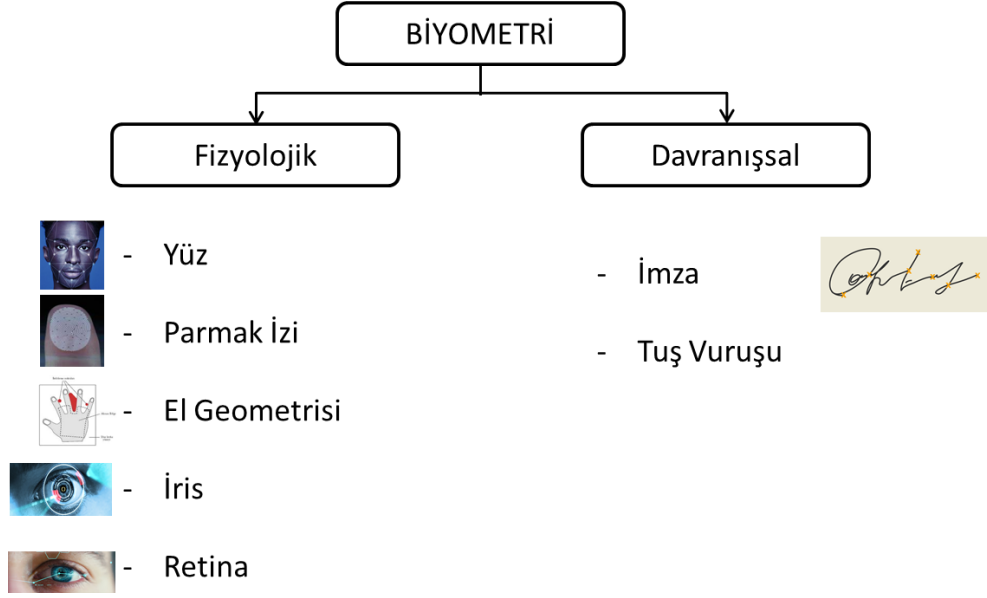


Şekil 1.1. Genel biyometrik tanıma sisteminin adımları

Genel biyometrik tanıma sisteminin görüntülerin alınması aşamasında kaynaktan sisteme biyometrik özelliğin görüntüsü aktarılmaktadır. Aktarılan görüntüde, görüntüyü iyileştirmek için çeşitli ön işlemler uygulanmaktadır. Özellik çıkarımı, kullanıcının diğer kullanıcılardan farkını ortaya koymak için taranan biyometrik veriden özellik çıkarma işlemlerini kapsamaktadır. Örüntü eşleştirme, giriş görüntüsünden özellikleri çıkarmak ve yapılan işlemlerden sonra veritabanında ki görüntüler ile eşleştirme işlemi yapmaktır. Karar aşamasında, örüntü eşleştirmenin sonucuna göre tanıma sağlanmaktadır. Veri tabanında, kullanıcıların biyometrik verileri tutulmaktadır.

Tüm biyometrik sistemler; evrensellik, eşsiz olma, süreklilik, elde edilebilirlik ve kabul edilebilirlik özelliklerine sahiptirler (Ergen ve Çalışkan, 2011).

Günümüzde biyometrik tanıma yöntemleri Şekil1.2 de gösterildiği gibidir (Şan, 2013). Yüz, parmak izi, retina, iris fizyolojik biyometri iken imza, tuş vuruşu gibi özelliklerde davranışsal biyometridir.



Şekil 1.2. Biyometrik Tanıma Sistemleri

Fizyolojik özelliklere dayalı olan tanıma sistemleri;

- *Parmak İzi Tanıma:* Parmak izi tanıma günümüzde oldukça yaygın bir şekilde kullanılmaktadır. Her parmak izi, üzerinde görünen girinti ve çıkıntılar sebebi ile kendine özgüdür. Parmak izi tanıma işlem adımları genel olarak parmak izinin elde edilmesi, elde edilen parmak izi görüntülerinin ön işlenmesi ve ön işlenmiş parmak izi görüntülerinin tanınması şeklinde sıralanabilir (Kurbanov, 2018).

- *İris Tanıma:* Gözbebeğinin önünde bulunan daire şeklinde göze rengini veren renkli tabakaya iris denilmektedir. İris insanın hayatı boyunca cerrahi müdahale ile bile değişmeyen tek organıdır(Yıldız ve Baykan, 2011). Tanımda yapılan ilk işlem görüntüden iris bölgesinin bulunmasıdır (Sisnelioğlu, 2014). Günümüzde iris tanıma hava alanları, sınır kapıları gibi birçok yerde kullanılmaktadır (Kurbanov,2018).

- *El Geometrisi Tanıma:* El geometrisi tanıma biyometrik sistemleri, kişilerin parmak uzunluğu, parmak genişliği, parmak kalınlığı, parmak alanı, büküm noktaları ve avuç içi genişliği gibi özellikleri incelemektedir. Askeriyelerde, havaalanlarında ve güvenlik gerektiren nükleer güç istasyonu gibi yerlerde kullanılmaktadır (Parlak yıldız, 2014).

- *Retina Tanıma:* Retina tanıma işlemi insanın göz bebeği arkasındaki damar tabakanın tanınmasıdır. Retina bölgesindeki damarlar her göze özgü

yapıdadır ancak göz hastalıklarından damarların etkilenmesi söz konusu olduğu için tercih edilen bir yöntem değildir(Sisnelioğlu, 2014; Delac, 2004).

- *Ses Tanıma*: Ses insanları veya canlı türlerini birbirinden ayırmak için kullanılan biyometrik bir özelliktir (Özkaynak, 2013). Ses tanıma da sesin dijital bir veriye değiştirilip kaydedilmesiyle ve daha sonra diğer örneklerle kıyaslama yapılmasıyla tanıma sağlanması amaçlanmaktadır (Parlak yıldız, 2014).

- *Damar Tanıma*: Her insanın damar yapısı diğerlerinden farklıdır. Damar tanıma teknolojisinde kandaki hemogloblin kullanıldığından dolayı tanımlama yapılan uzvun canlı olması, damar içinde kan bulunması önemlidir (Şan, 2013). Damar tanıma teknolojisinin, diğer teknolojilere göre en büyük avantajı elin kesilmesi, zedelenmesi durumlarında damar yapısı etkilenmeyeceği için çalışmaya devam etmesidir (Sisnelioğlu, 2014). Havaalanları, hastaneler, devlet kurumları gibi yerlerde kullanılmaktadır.

- *Yüz Tanıma*: İnsanlık tarihinden bu yana, insanlar birbirlerini tanımada yüzlerinden faydalanırlar (Şan, 2013). Yüz tanıma işlemi, yüz ifadelerindeki farklılıklar, aydınlatma koşulları, makyaj, poz farklılıkları, saç şekli, yüzün bir kısmını veya tamamını kapatan aksesuarlar gibi birçok unsur olması sebebi ile oldukça karmaşıktır. Fabrikalar, personel takip sistemleri, metrolar, hastane giriş çıkışları gibi birçok uygulama alanı mevcuttur.

Davranışsal özelliklere dayalı olan biyometrik tanıma sistemleri;

- *İmza Atımı*: İmza, günlük yaşantıda, milyonlarca kişi tarafından çok sık şekilde kullanılmaktadır. İmza tanıma işlemlerinde imza şekilleri, kalemin tutuş yönü, yazma baskısı, çizgi uzunluğu ve eğrilik yarıçapı ölçümleri kullanılır (Kuerban, 2018).

- *Tuş Vuruşu*: Bir bilgisayar veya benzeri bir cihazda klavye ile yazış karakteristiklerini gösteren bir davranış özelliğidir(Kuerban, 2018). Tuş vuruş dinamikleri sadece kullanıcı tanımada değil, sosyal ağlarda kullanıcıların cinsiyetinin tahmin edilmesinde de kullanılabilir (Fairhurst vd.).


1.2- Yüz Tanıma

Kişi tanıma; bir kişinin fiziksel karakteristikleri veya kişisel özellikleri kullanılarak kimliğinin belirlenmesi veya doğrulanması ile sağlanır (Filiz, 2012). Kişi tanıma; bireyin yüzü, parmak izi, retina, ses ve konuşma gibi fiziksel veya davranışsal biyometrik özellikleri kullanılarak yapılabilir.

Biyometrik tanıma sistemlerinden biri olan yüz tanıma çok uzun süredir üzerinde çalışılan alanlardan biridir. Yüz tanıma son yıllarda oldukça popüler hale gelen yüz bilgilerini kullanarak görüntülerin analiz edilmesi ve anlamlandırılmasına dayalı bir sistemdir.

Yüz tanıma sistemleri havaalanları, askeri yerler, personel giriş çıkış kontrolü, otomatik kimlik doğrulama gibi birçok alanda kullanılmaktadır.

Yüz tanıma sisteminin çalışma prensibi; öncelikle yüz tespit edilir, tespit edilen yüze ön işlem uygulanarak öznitelik çıkarımı için uygun hale getirilir. Daha sonra öznitelik çıkarımıyla öznitelikler bulunur, bulunan öznitelikler kullanılarak yüz tanınması Şekil 1.3 deki gibi yapılır.



Şekil 1.3. Yüz Tanımının Aşamaları

Bu aşamalar ayrıntılandırılacak olursa görüntü girişinde yüz tespiti yapıldıktan sonra ön işleme aşamasında yüzlerin temizlenmesi, ışıktan kaynaklanan görüntü bozukluklarının düzeltilmesi, yüzün konumlandırılması gibi işlemler gerçekleştirilir.

Öznitelik çıkarımı aşamasında Temel Bileşen Analizi (PCA) (Imran vd., 2015), Bağımsız Bileşen Analizi (ICA) (Comon, 2015), Doğrusal Ayırtaç Analizi (LDA) (Martinez ve Kak, 2001) gibi alt uzay teknikleri, Ayrık Kosinüs Dönüşümü (DCT) (Ping vd., 2010) gibi dalgacık teknikleri, SOM (Tan vd., 2009) gibi yapay sinir ağları, Yerel İkili Örüntüler (LBP) (Ojala vd., 1996) gibi yüzün yerel özelliklerini kullanan teknikler kullanılabilir. Kullanılan her tekniğin uygulandıkları alanlara göre artı ve eksileri olabilmektedir. Sınıflandırma aşamasında ise Doğrusal Regresyon Sınıflandırıcı (LRC) (Naseem vd, 2010), ki-kare istatistiği, Bayes sınıflandırıcısı, SR (Jia ve Martinez, 2009) sınıflandırıcısı,

Destek Vektör Makinesi (SVM) (Li ve Imai, 2010) gibi sınıflandırıcı çeşitlerinden biri kullanılabilir.

Yüz tanıma yaygın olarak kullanılan bir biyometrik sistemdir. Yüz tanıma yapılırken birçok zorlukla karşılaşılır. Bunlar; görüntü kalitesi, aydınlatma sorunu, poz varyasyonu gibi problemlerdir. Bunlara rağmen yüz tanıma sistemlerinin performansı her geçen gün gelişmektedir ve geliştirilen her yöntemle daha iyi sonuçlar vermektedir.


Bu çalışmada yüz tanıma probleminin öznitelik çıkarımı aşamasında Yerel İkili Örüntüler, sınıflandırma aşamasında Doğrusal Regresyon Sınıflandırıcısı ve Ki-kare istatistiği kullanılmıştır.

2.YEREL İKİLİ ÖRÜNTÜLER

Yerel İkili Örüntüler (LBP – Local Binary Patterns) ilk olarak Ojala tarafından 1996’da geliştirilmiş bir öznitelik çıkartma yöntemidir(Ojala vd., 1996). LBP öznitelik çıkarımı doku sınıflandırması (Kazak ve Koç, 2016), yüz tanıma (Ahonen vd., 2006), yaşın belirlenmesi (Nabiyev ve Günay, 2011), cinsiyet belirleme (Lian ve Lu, 2006), yüz ifadesi tanıma (Shan vd., 2009) vb. uygulamalarda kullanılmaktadır.

LBP’nin ayırt edici avantajı olarak aydınlatma değişikliklerine karşı gürbüz olması ve hesaplanabilir basitliği iken dezavantajı olarak da gürültüye karşı son derece hassas olması söylenebilir.

LBP gri görüntüdeki her pikselin 3×3 komşuluklarını karşılaştırarak ikili kodlar üretir. Elde edilen 3×3 ’lük görüntü dairesel olarak ele alınır. Merkez piksel eşik değeri kabul edilir. Komşu piksel değeri ile merkez piksel değeri karşılaştırıldığında, komşu pikselin değeri merkez pikselin değerinden büyük veya eşitse ikilik tabanda 1, komşu pikselin değeri merkez pikselin değerinden küçük ise ikilik tabanda 0 olarak kodlanır. 8 bitlik ikili kod oluşturulup onluk sisteme çevrilerek merkez pikselin LBP kodu elde edilir. Yapılan bu işlem görüntünün her pikseli için hesaplanır. Oluşturulan LBP kodu ile görüntüdeki farklı tipteki özellikleri belirlemek mümkündür. Kenarlar, köşeler, aydınlık veya karanlık bölgeler, çizgi bölgeleri gibi yerler örnek verilebilir (Kızrak, 2014).



İkilik Taban: 11010101

Onluk Taban: 213

Şekil 2.1. LBP Operatörünün Hesaplanması


Kısaca bir pikselin konumuna (x_i, y_i) bakıldığında, LBP, merkez piksel ile onu çevreleyen komşu pikseller arasındaki değerlerin karşılaştırılmasıyla 8 bitlik kod oluşturulup, onluk sisteme çevrildiğinde *LBP* kodu elde edilir (Sánchez López, 2010). Görüntüdeki her piksel için komşu pikseller merkez piksele göre eşiklendirilerek ikili kod üretilir. LBP kodlarının üretimi aşağıdaki denklemdeki gibidir.

$$LBP(x_i, y_i) = \sum_{n=0}^{n-1} s(g_n - g_i)2^n \quad (2.1)$$

Eşitlikte; (x_i, y_i) merkez pikselin koordinatları, g_i merkez pikselinin gri değerini, g_n ise merkez pikseli çevreleyen 3x3 komşuluktaki piksellerin değerlerini ifade etmektedir. $s(k)$ fonksiyonu gri piksellerin 8 komşuluk değerleridir.

$$s(k) = \begin{cases} 1 & \text{eğer } k \geq 0 \\ 0 & \text{ğer } k < 0 \end{cases} \quad (2.2)$$

LBP operatöründe standart 3×3 komşuluk dışında farklı dairesel komşuluklar vardır. Farklı dairesel komşuluklar çeşitli boyutlardaki görüntülerin analizlerinin daha iyi sonuçlanmasını sağlamıştır (Kurt vd., 2007). Komşuluklarına göre farklı LBP operatörleri tanımlanabilir. Genel olarak $LBP_{P,R}$ farklı dairesel simetrik komşuluklar kümesi olarak tanımlanabilir, P komşu sayısını, R ise örnekleme yarıçapını gösterir. Piksellerin tam ortasında olmayan komşuların gri değerleri enterpolasyon ile tahmin edilir (Ojala vd., 2002).



Şekil 2.2. P örnek sayısı ve R simetrik dairesel yarıçap çeşitleri

Yapılan çalışmalarda tekdüze LBP (ULPB) nin görüntülerde çoğunlukta olduğu görülmüştür. Tekdüze örüntüler, ikilik tabanda LBP kodu incelendiğinde 0-1 veya 1-0 geçiş sayısı 2 veya daha az olanlardır. Tekdüze olmayan örüntüler, ikilik tabanda 0-1 veya 1-0 geçiş sayısı ikiden fazla olanlardır. Örneğin 00000000 ve 111111 örüntüleri 0 geçişe sahip iken 01110000 ve 11001111 örüntüleri 2 geçişe sahip olduklarından tekdüzedir. 11001001 4 geçişli ve 01010011 6 geçişli olduğu için tekdüze değildir. Çalışmalarda düzgün örüntülerin araştırılan doku yüzeylerinde %90'ın üzerinde bir çoğunluğa sahip olduğu görülmüştür (Ojala vd., 2002).


LBP histogramı çıkarılırken tekdüze örüntüler kullanıldığından, histogramda her bir tekdüze örüntü için bir bölme bulunurken, tekdüze olmayan örüntülerin hepsi tek bir bölmede toplanmaktadır. Tüm örüntülere bakıldığında 8 komşuluk için 256 adet farklı kod oluşmaktadır. 58 tanesinin tekdüze olduğu görülmektedir. Bunlar 0000000, 00000001, 00000011, 00000111, 00001111, 00011111, 00111111, 01111111, 11111111 ve bu kodların dairesel olarak döndürülmesi ile elde edilen örüntülerdir. Böylece LBP histogramı 59 bölmeye sahip olacaktır.

2.1-Yüzden LBP Kodlarının Elde Edilmesi

Histogramlar yüz resmindeki kenarlar, düz alanlar gibi mikro-örüntüler ile ilgili bilgileri taşır. Daha verimli sonuçlar alabilmek için bölgesel histogramlar kullanılabilir. Bu amaçla yüz resminin bulunduğu görüntüler R_0, R_1, \dots, R_{m-1} ile ifade edilen m dikdörtgensel bölgeye ayrılıp, her bölge için LBP kodları ayrı ayrı hesaplanıp histogramlar elde edilebilir. Elde edilen bu histogramlar birbirlerine ucuca eklenip öznitelik vektörü olarak sınıflandırmada kullanılabilirler.


$$H_i = \sum_{x_c \in I(x,y)} \{LBP_{8,1}\}(x_i) \quad i = 0,1, \dots, m-1 \quad (2.3)$$

Denklemden $I(x,y)$ giriş görüntüsünün i . bölgesi olmak üzere, 1 piksel uzaklıktaki 8 komşuluk için H_i , i . bölgeye ait LBP histogramında ki değeri ifade etmektedir. Şekil 2.3'te bir yüz resminin 3×3 , 5×5 ve 7×7 bölgeye ayrılmış varyasyonları görülmektedir.




Şekil 2.3. 3×3, 5×5 ve 7×7'ye bölünmüş yüz görüntüleri

Yapılan deneylerde görüntüler $5 \times 5 = 25$ bölgeye bölünmüş olup her bölgenin $R = 1$ yarıçap ve $P = 8$ komşuluk için 59 boyutlu tekdüze LBP histogramları Şekil 2.4'deki gibi oluşturulmuştur. Oluşturulan bu histogramlar birleştirilip tek bir histogram elde edilmiştir. Histogramlar uçuca eklendiğinde oluşturulan $59 \times 25 = 1475$ boyutlu öznitelik vektörü Şekil 2.5 de gösterilmiştir.



Şekil 2.4. 5×5 bölgeye ayrılmış görüntüde histogramlar




Şekil 2.5. $59 \times 25 = 1475$ boyutlu uçuca eklemiş histogram

2.2-Ağırlıklandırma

Yüz tanıma sistemlerinde özellikler çıkarılırken kullanılacak yöntemlere bağlı olarak referans noktaları, çizgiler veya gözler, burun, ağız gibi yüz özellikleri kullanılmaktadır. Yüz tanımda bazı özelliklerin diğer özelliklere göre daha önemli rol oynadığını gösteren psikofiziksel bulgulara dayanarak (Zhao vd., 2003), yüzdeki bazı bölgelerin, yüz ifadelerinden dolayı daha fazla katkıda bulunduğu düşünülmektedir. Örneğin göz çevresi, burun, ağız, önemli bölgeler iken alın, yanak gibi gölgelerin önemi bu bölgelere oranla daha düşüktür (Nabiyev ve Günay, 2011). Birçok yüz tanıma sistemi yüz tanıma yapabilmek için gözler, burun ve ağız gibi temel yüz özelliklerinin doğru konumlarına ihtiyaç duyarlar.

Öznitelikler belirlenirken bu bölgelerin önem derecesine bağlı olarak Şekil 2.6'da görüldüğü gibi ağırlıklandırma yapılmıştır. Ağırlıklar bir optimizasyon yöntemi kullanılmadan bölgelerin önem derecelerine göre seçilmişlerdir. Ağırlıklandırma işleminde yüz bölgeleri önem derecelerine göre değerlendirilirken, yüzün önemli bölgelerinden önemsiz bölgelere doğru artan şekilde ağırlıklar seçilmişlerdir. Yüzde bulunan bölgelere sırasına göre gözler, burun ve ağıza; 4, göz çevresi ve ağız çevresine; 2, yanak ve kaş ortasına; 1, yanaklara; 0 katsayıları verilmiştir (Ahonen vd., 2006; Shan vd., 2009).



Şekil 2.6. 5×5 'e bölünen yüz görüntüsü, (b) Bölünmüş resme her bölge için uyguladığımız ağırlıklar. Siyah kare 0, koyu gri 1, açık gri 2, beyaz 4 ü temsil etmektedir. (c) Ağırlık verilen resmin görünümü.

Ağırlıklandırma yapılarak, öznitelik çıkarımında bölgelerin histogramların da oluşturulan farklılık ile katkısı incelenmiştir. Bölgelerin önem derecelerine

göre verilen katsayıların belirlenmesi ileride yapılabilecek çalışmalarda üzerinde durulup deęişiklikler yapılarak deneysel çalışmalar iyileştirilebilir.

3.SINIFLANDIRICILAR

Bu bölümde tez çalışmasında kullanılan LRC ve χ^2 sınıflandırıcıları hakkında bilgi verilecektir. LRC yöntemi çoğunlukla yüz tanıma problemlerinde kullanılan bir alt uzay tabanlı sınıflandırma yöntemi iken, χ^2 histogramların karşılaştırılmasında kullanılan istatistiksel bir yöntemdir.

3.1-Doğrusal Regresyon Analizi

Regresyon, bağımlı ve bağımsız değişken(ler) arasındaki ilişkiyi ve doğrusal eğri kavramını kullanarak, bir tahmin eşitliği geliştirir. Değişkenler arasındaki ilişkiyi belirledikten sonra, bağımsız değişken(ler)in değeri bilindiğinde bağımlı değişkenin değeri tahmin edilebilir(Köse, 2012).

Doğrusal regresyon y olarak adlandırılan sayısal bağımlı değişken ile x olarak ifade edilen bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modelleme yaklaşımıdır.

Regresyon analizinde;

- a) Bağımlı değişken bir, bağımsız değişken bir ise, yöntemine basit regresyon analizi,
- b) Bağımlı değişken bir, bağımsız değişken iki ya da daha fazla ise çoklu regresyon analizi,
- c) Bağımlı değişken iki ya da daha fazla ise çok değişkenli regresyon analizi denir (Büyüköztürk, 2002).

Regresyon analizi, bağımlı değişkenin bağımsız değişken veya değişkenlerden herhangi birinin değişimine bağlı olarak nasıl değişim gösterdiğini incelemektedir. Regresyon analizi, iş yaşamı ve davranış bilimleri başta olmak üzere, sosyal ve fen bilimlerinde ve bir çok farklı disiplinlerde sıklıkla kullanılmaktadır (Weisburg, 2005).

Verideki her x değeri için y değerlerini temsil edebilecek y'nin kestirim değerlerini bulmaktır. Doğrusal regresyon analizinde bunu aşağıdaki denklem sağlamaktadır:

$$y = a + bx \quad (3.1)$$

x değişkeni: Başka bir değişken tarafından etkilenmeyen, y 'yi etkileyen değişkendir. x değişkeni çoğu defa bağımsız değişken adını alır ve hatasız ölçüldüğü varsayılır.

y değişkeni: x değişkenine bağlı olarak değişen değişkendir. y değişeni çoğu defa bağımlı değişken adını alır ve belli bir hataya sahip olduğu varsayılır.

a katsayısı: Sabit bir değer olup $x = 0$ olduğunda regresyon doğrusunun y eksenini kestiği noktayı gösterir.

b katsayısı: Regresyon katsayısıdır. b katsayısı, x değişkenindeki bir birimlik değişimin bağımlı değişkende yapacağı ortalama değişiklik miktarını verir.

Bir regresyon modeli oluşturulurken en küçük kareler ve en büyük olabilirlik teknikleri olan iki yaklaşımdan birisi kullanılır. Yapılan deneysel çalışmalarda en küçük kareler yöntemi kullanılmıştır.

Yapılan deneysel çalışmalarda; sınıf modelleri X_i 'ler aşağıdaki denklemden gibi oluşturulmuştur.

$$X_i = [a_i^1 : \dots : a_i^j : \dots : a_i^N] \quad (3.2)$$

Denklemden a_i^j i . sınıfın j . özellik vektörüdür. y aynı sınıftan alınan eğitim görüntülerinin doğrusal birleşimidir ve şu şekilde tanımlanır:

$$y = X_i \beta_i + \varepsilon \quad (3.3)$$

En küçük kareler tahminiyle hesaplanan parametrelerin vektörüdür β_i 'dir.

$$\widehat{\beta}_i = (X_i^T X_i)^{-1} X_i^T y \quad (3.4)$$

y 'nin yaklaşık değeri:

$$\widehat{y}_i = X_i (X_i^T X_i)^{-1} X_i^T y \quad (3.5)$$

Orijinal vektör ile izdüşümü alınmış vektör arasındaki uzaklık en küçük kareler yöntemine dayalı olarak hesaplanır. Sınıflandırma işlemi hesaplanan uzaklıklara göre yapılır. Her sınıf için minimum uzaklık bulunur:

$$\operatorname{argmin}_i \{\|y - \widehat{y}_i\|\}, \quad i = 1, 2, \dots, C. \quad (3.6)$$

3.2-Ki Kare İstatistiği (χ^2)

Ki-kare testi, histogramların karşılaştırılmasında sıklıkla kullanılan istatistiksel bir benzersizlik ölçütüdür (Kazak Çerçevik, 2018):

$$\chi^2(P, Q) = \sum_i \frac{(p_i - q_i)^2}{(p_i + q_i)} \quad (3.7)$$

Burada P ve Q iki görüntüye ait histogramlardır. p_i ve q_i , P ve Q histogramlarının i . çubuktaki değerleridir. Yapılan deneysel çalışmalarda genel histogram yerine görüntü belirli bölgelere ayrılarak yerel histogramlar oluşturulur. Yüz tanımada yüzün bazı bölgeleri diğer bölgelere oranla daha önemli bilgiler taşımaktadır. Bu nedenle, bu bölgelere önemine göre ağırlıklar verilerek hesaplanan χ^2 istatistiği:

$$\chi_w^2(P, Q) = \sum_{i,j} w_{i,j} \frac{(p_{i,j} - q_{i,j})^2}{p_{i,j} + q_{i,j}} \quad (3.8)$$

$p_{i,j}$ ve $q_{i,j}$, j . bölgeye karşılık gelen histogramın i . bölmesini ifade etmektedir. $w_{i,j}$ de j . bölgenin ağırlığıdır.

4.DENEYSEL ÇALIŞMALAR

Deneysel çalışmalarda AR ve Genişletilmiş Yale Yüz Veri Tabanı B kullanılmıştır. Bu veri tabanlarındaki görüntüler bölgelere ayrılıp her bölgenin LBP histogramları ile öznitelikleri elde edilmiştir. Öznitelikleri çıkarılan görüntüleri sınıflandırma aşamasında LRC sınıflandırıcısı ve χ^2 istatistiği kullanılmıştır. Deneylerde bu yöntemlerin sınıflandırma başarımları ölçülmüştür.


4.1-Veri Tabanları

4.1.1- AR Veri Tabanı

AR veri tabanı 126 farklı kişiye ait 4000'nin üzerinde renkli görüntü içerir (Martinez, 1999). 126 kişinin 70'i erkek ve 56'sı kadından oluşmaktadır. Bu görüntüler yüz ifade değişiklikleri, gözlük, atkı ve aydınlatma koşulları ile ilgili yüz tanımayı zorlaştıran etmenler içermektedir. Hizalama, ölçeklendirme, yerleştirme, kırma ve yeniden boyutlandırma işlemlerinden sonra, görüntülerin son boyutu 115×87 piksel olmuştur (Koç, 2012). Şekil 4.1'de kişinin yüz ifadeleri, gözlüklü, atkılı ve ışıklandırma değişimlerini içeren görüntüleri gösterilmektedir. Atkılı görüntülerin yüzü kapama oranı yaklaşık %40, gözlüklü görüntülerin yüzü kapama oranı yaklaşık %20'dir. Görüntüler her kişi için 2 hafta arayla iki oturumda elde edilmiştir. Şekil 4.2'de AR yüz veri tabanında bir kişinin ikinci oturumdan elde edilen görüntüleridir.



Şekil 4.1. AR yüz veri tabanında bir kişinin ilk oturumdan edilen görüntüleri



Şekil 4.2. AR yüz veri tabanında bir kişinin ikinci oturumdan edilen görüntüleridir.

4.1.2-Genişletilmiş Yale Yüz Veri tabanı B


Genişletilmiş Yale yüz veri tabanı 9 pozlama ve 64 aydınlatma koşulu altında 28 kişinin 16128 görüntüsünü içerir. Bu veri tabanından kırılmış görüntülerini kullanıyoruz. 38 farklı kişiden alınan 64 görüntüden oluşan bir veri tabanıdır. Görüntülerin boyutu 192×168 pikseldir. Genişletilmiş Yale Yüz Veri Tabanı B Şekil4.3'de görüldüğü gibidir.



Şekil 4.3. Genişletilmiş Yale yüz veri tabanında bir kişinin görüntüleri

4.2-AR Veri Tabanındaki Deneyler

AR veri tabanında 30 erkek 20 bayandan oluşan 50 kişilik bir alt küme deneysel çalışmalarda kullanılmıştır. Her bir görüntünün orijinal boyutu 768×576 'dır. Arka planın temizlenmesi, gözlerin belirli koordinatlara sabitlenmesi ve yeniden boyutlandırma gibi ön işlemlerden sonra görüntülerin boyutu 115×87 olmuştur. Yapılan deneysel çalışmalarda görüntüler $5 \times 5 = 25$ bölgeye ayrılmıştır. Daha sonra her bir kişiye ait 14 görüntüden 7'sini eğitim aşamasında kullanılmak üzere rastgele seçilmiştir. Kalan görüntüler ise test aşamasında kullanılmıştır. Daha güvenilir sonuçlar elde etmek için bu işlemler 10 defa tekrar edilmiştir. Deneyler yapılırken daha iyi sonuçlar alabilmek için görüntülere ağırlıklandırma yaparak da aynı deneyleri tekrar edilmiştir. Şekil 4.4'de gösterildiği gibi bölgelere ayrılan görüntülere verilen ağırlıklandırma $w_n = [1 \ 1 \ 1 \ 1 \ 1; 2 \ 4 \ 1 \ 4 \ 2; 0 \ 1 \ 4 \ 1 \ 0; 0 \ 2 \ 4 \ 2 \ 0; 0 \ 1 \ 1 \ 1 \ 0]$ şeklindedir.



Şekil 4.4. AR veri tabanında deney yapılan görüntünün 5×5 bölgeye ayrılmış görüntü (solda), kullanılan ağırlık matrisi (ortada), koyu renkler bölgenin düşük öneme sahip olduğunu göstermektedir (sağda).

AR veri tabanında yapılan deneysel çalışmalarda öznitelik çıkarım yöntemi olarak $uLBP_{(8,1)}$ ve $LBP_{(8,1)}$ yöntemi kullanılmıştır.

Yapılan ilk deneyde görüntülerin $uLBP_{(8,1)}$ öznitelikleri elde edildikten sonra sınıflandırma başarımları test edilmiştir. Deney sonuçları Çizelge 4.1'de görülmektedir. Bu çizelgede $uLBP - LRC$ görüntü bölgelere ayrılmadan LBP histogramları kullanılarak LRC yöntemi ile elde edilen sınıflandırma sonuçlarını göstermektedir.

Diğer deneysel çalışmalarda daha verimli sonuçlar elde edebilmek için görüntü ilk olarak $5 \times 5 = 25$ bölgeye ayrılmıştır. Bölgelere ayrılmış görüntülerin

$uLBP$ ile öznitelikleri çıkarıldıktan sonra resmin her bir bölgesinin $uLBP$ histogramı uçuca eklenerek vektör haline getirilmiştir. Çizelge 4.1’de $uLBP^{5 \times 5} - LRC$ bu öznitelik vektörlerinin LRC ile sınıflandırılması sonuçlarını göstermektedir. $uLBP_W^{5 \times 5} - LRC$ her bölgeden elde edilen öznitelik vektörlerinin bölgelerin önem derecelerine göre daha önceden belirlenen W ağırlıkları ile çarpıldıktan sonra uçuca eklenmesi ile elde edilen öznitelik vektörünün LRC ile sınıflandırılması sonuçlarını göstermektedir. Diğer deneylerde sınıflandırma yöntemi olarak histogramların karşılaştırılmasında kullanılan χ^2 istatistiğinden yararlanılmıştır. Benzer şekilde $uLBP^{5 \times 5} - \chi^2$ ve $uLBP_W^{5 \times 5} - \chi^2$ deneyleri öznitelik vektörleri için tekrarlanmıştır.

Çizelge 4.1. AR veri tabanında $5 \times 5 = 25$ bölgeye ayrılıp tekdüze $uLBP_{(8,1)}$ öznitelik çıkarımı uygulanan deneysel çalışmalar.

Deneyler	$uLBP - LRC$	$uLBP^{5 \times 5} - LRC$	$uLBP_W^{5 \times 5} - LRC$	$uLBP^{5 \times 5} - \chi^2$	$uLBP_W^{5 \times 5} - \chi^2$
1	98	96,28	97,14	95,42	91,42
2	96,28	96	94,85	94	88,85
3	96,85	95,71	95,14	95,42	90,28
4	96,85	96,28	94,85	94,42	89,42
5	97,71	95,14	94,57	94,85	90
6	98,57	97,14	96,57	95,71	90
7	98,28	97,71	97,14	94,28	87,42
8	96,57	96	92,28	94	86
9	96	95,71	96	94,85	89,14
10	95,71	94,85	94,85	92,85	88,57
Ortalama	97,08	96,08	95,34	94,58	89,11
σ^2	0,99	0,85	1,45	0,85	1,53

Yapılan ikinci deneyde, görüntülerin $LBP_{(8,1)}$ öznitelikleri elde edildikten sonra sınıflandırma yöntemi olarak LRC ve χ^2 istatistiği kullanılmıştır. Yapılan deneylerde bölgelerin önem derecelerine göre daha önceden belirlenen

W ağırlıkları ile öznitelik vektörleri çarpılarak sonuçlar elde edilmiştir. Çizelge 4.2’de $LBP_{(8,1)}$ öznitelikleri ile elde edilen deney sonuçları görülmektedir.

Çizelge 4.2. AR veri tabanında $5 \times 5 = 25$ bölgeye ayrılıp $LBP_{(8,1)}$ öznitelik çıkarımı uygulanan deneysel çalışmalar.

Deneyler	$LBP - LRC$	$LBP^{5 \times 5} - LRC$	$LBP_W^{5 \times 5} - LRC$	$LBP^{5 \times 5} - \chi^2$	$LBP_W^{5 \times 5} - \chi^2$
1	98,28	96,28	96,85	96,57	92,57
2	96	95,71	95,14	94,57	89,71
3	96,85	95,42	95,14	96,28	90
4	96,85	95,42	94,85	95,42	90,28
5	97,71	95,71	96,85	96	90,57
6	98	96,57	94	96,85	90,57
7	98,28	98	97,14	95,42	88,57
8	96,28	96,28	92,85	94,57	86,85
9	96,82	94,85	96	94,85	89,42
10	95,42	94,85	94,85	94,28	90,28
Ortalama	97,05	95,91	95,37	95,48	89,88
σ^2	0,99	0,89	1,72	1,54	3,35

AR veri tabanında yapılan deneysel çalışmalarda öznitelik çıkarım yöntemi olarak $uLBP_{(8,1)}$ ve $LBP_{(8,1)}$ yöntemi kullanılmıştır. Bu deneyler yapılırken eğitim ve test aşamasındaki görüntüler rastgele seçilmişlerdir. Bu deneyde eğitim aşamasında veri tabanındaki ilk 7 görüntü eğitim seti kalan görüntüler test aşamasında kullanılmıştır. Eğitim aşamasındaki görüntülerde kişinin yüzünde tanımayı engel kapatma yoktur. Bu sebeple eğitim aşamasında kullanılacak görüntülerin seçilmesi Çizelge 4.3’de de görüldüğü gibi deney sonuçlarındaki tanıma başarımını arttırmıştır.

Çizelge 4.3. Eğitim aşamasında seçilen görüntüler ile yapılan deney sonuçları.


	$LBP - LRC$	$LBP^{5 \times 5} - LRC$	$LBP_W^{5 \times 5} - LRC$	$LBP^{5 \times 5} - \chi^2$	$LBP_W^{5 \times 5} - \chi^2$
$uLBP_{(8,1)}$	93,71	97,71	99,42	99,14	99,71
$LBP_{(8,1)}$	93,42	96,28	99,14	99,71	100

Üçüncü deneyde $uLBP_{(16,2)}$ öznelikleri elde edildikten sonra sınıflandırma başarımları test edilmiştir. Deney sonuçları Çizelge 4.4’de görülmektedir. Deneysel çalışmalarda daha verimli sonuçlar elde edebilmek için görüntüler diğer deneylerdeki gibi $5 \times 5 = 25$ bölgeye ayrılmıştır. Bölgelere ayrılmış görüntülerin $uLBP$ ile öznelikleri çıkarıldıktan sonra görüntünün her bir bölgesinin $uLBP$ histogramı uçuca eklenerek vektör haline getirilmiştir. Diğer deneylerde uygulanan LRC ve χ^2 istatistiği sınıflandırma yöntemleri kullanılmıştır.

Çizelge 4.4. AR veri tabanında $5 \times 5 = 25$ bölgeye ayrılıp $uLBP_{(16,2)}$ öznelik çıkarımı uygulanan deneysel çalışmalar.

Deneyler	$uLBP - LRC$	$uLBP^{5 \times 5} - LRC$	$uLBP_W^{5 \times 5} - LRC$	$uLBP^{5 \times 5} - \chi^2$	$uLBP_W^{5 \times 5} - \chi^2$
	94,28	97,14	99,42	100	100
1	98,85	98,57	98,85	98,57	97,14
2	97,42	97,42	98	96,28	94,57
3	98,28	96	95,71	98	95,14
4	97,42	97,42	97,42	97,71	95,14
5	98,28	95,14	96	96,85	95,71
6	99,14	99,42	98,85	99,14	97,14
7	99,14	96,85	97,14	98,57	96,28
8	98,57	96,85	95,14	98	96,28
9	97,71	95,42	96	97,42	96,28
10	97,71	96,28	95,14	97,14	94,85
Ortalama	98,25	96,93	96,82	97,76	95,85
σ^2	0,66	97,14	1,42	0,87	0,91

LBP öznitelik çıkarımında komşu sayısı ve örnekleme yarıçapı arttırıldığında tanıma sistemi daha verimli sonuçlar vermiştir. Şekil 4.5’de birinci deneyde gerçekleştirilen $uLBP_{(8,1)}$ öznitelik çıkarımı ile üçüncü deneyde gerçekleştirilen $uLBP_{(16,2)}$ öznitelik çıkarımında aynı deneyler yapıldığında sonuçları karşılaştırılmıştır.



Şekil 4. 5. $uLBP_{(8,1)}$ öznitelik çıkarımı $uLBP_{(16,2)}$ öznitelik çıkarımının grafiksel karşılaştırması

Yapılan deneysel çalışmalara ilave olarak AR veri tabanında *LRC* yöntemi öznitelik çıkarımı aşamasında kullanılmıştır. Yapılan ilk deneyde görüntülere *LRC* öznitelik çıkarımı yapılarak sonuçlar elde edilmiştir. Daha sonra görüntüler $5 \times 5 = 25$ bölgelere ayrılarak vektör haline getirilmiş ve her bölgeye *LRC* yöntemi uygulanmıştır. Diğer deneysel çalışmalardaki gibi bu deneylerde de ağırlıklandırmanın etkisini gözlemleyebilmek için önce ağırlıksız sonra önem derecelerine göre ağırlıklandırma yapılarak sonuçlar elde edilmiştir. Çizelge 4.5’de *LRC* yöntemi ile yapılan deney sonuçları görülmektedir.

Çizelge 4. 5.AR veri tabanında LRC yöntemi ile yapılan deney sonuçları.

DENEYLER	LRC	LRC^{5×5}	LRC_w^{5×5}
1	94,85	97,71	97,14
2	92,28	96,28	94,57
3	93,71	95,14	92
4	92,57	96,28	93,14
5	95,14	97,14	95,71
6	93,42	97,71	94,28
7	92,57	97,42	94,85
8	90,28	95,71	92,57
9	92,57	96	95,14
10	92,28	96,57	92,85
Ortalama	92,97	96,6	94,22
σ^2	1,29	0,87	1,59

4.3- Genişletilmiş Yale -Yüz Veri Tabanı B'deki Deneyler

Genişletilmiş Yale yüz veri tabanı B de 38 kişinin farklı aydınlatma düzeylerinde çekilmiş 64 görüntüsü vardır. Bu veri tabanından kırılmış yüz görüntülerinin boyutu 192×108 pikseldir. Yapılan deneysel çalışmalarda görüntüler $10 \times 10 = 100$ bölgeye ayrılmıştır. Daha sonra her bir kişiye ait 64 görüntüden 32'si eğitim aşamasında kullanılmak üzere rastgele seçilmiştir. Kalan görüntüler ise test aşamasında kullanılmıştır.

Yale B veri tabanında deneyler yapılırken görüntülerin aydınlatma kontrastlarını dengeleyebilmek için filtre uygulanmıştır. Uygulanan filtrede görüntülere logaritmik işlem yapılmıştır. Logaritmanın bir görüntüye uygulanması, parlak piksel değerlerinin aralığını sıkıştırıp, karanlık piksel değerlerinin aralığını genişletmektedir.


$$I = (x, y) = L(x, y)R(x, y) \quad (4.1)$$

I verilen yüz görüntüsüdür. $L(x, y)$ ve $R(x, y)$ sırasıyla (x, y) noktasındaki aydınlık ve yansıtmadır.

$$I' = \log(I) = \log(L) + \log(R) = L' + R' \quad (4.2)$$

L' ve R' sırasıyla aydınlık ve yansıtma logaritmalarıdır. Görüntünün düşük frekans bölümünde yüksek geçiren filtre, yüksek- frekans bölümüne alçak geçiren filtre uygulanmıştır. Görüntülerdeki maksimum frekans olan bölgeler belirlenip aydınlatma koşulları iyileştirilmiştir.

Daha güvenilir sonuçlar elde etmek için bu işlemler 5 defa tekrar edilmiştir. Deneyler yapılırken daha iyi sonuçlar alabilmek için görüntülere ağırlıklandırma yaparak da aynı deneyler tekrar edilmiştir. 10 bölgeye ayrılan görüntülere verilen ağırlıklandırma Şekil 4.6'da görüldüğü gibidir.



Şekil 4.6. Yale B veri tabanında deney yaptığımız görüntünün 10×10 bölgeye ayrılıp ağırlıklandırılmış görüntüsü.

Yale B veri tabanında yapılan deneysel çalışmalarda öznitelik çıkarım yöntemi olarak $uLBP_{(8,1)} - f$ ve $uLBP_{(8,1)}$ yöntemi kullanılmıştır.

AR veri tabanında gerçekleştirilen deneylerin aynıları bu veri tabanında gerçekleştirilmiştir. $uLBP_{(8,1)}$ öznitelik çıkarımı olarak kullanılmıştır. Sınıflandırma aşamasında LRC ve χ^2 istatistiğinden faydalanılmıştır. Elde edilen sonuçlar Çizelge 4.6'de görülmektedir.

Çizelge 4. 6. Yale B veri tabanında $10 \times 10 = 100$ bölgeye ayrılıp $uLBP_{(8,1)}$ öznetelik çıkarımı uygulanan deneysel çalışmalar.

Deneyler	$uLBP - LRC$	$uLBP^{10 \times 10} - LRC$	$uLBP_W^{10 \times 10} - LRC$	$uLBP^{10 \times 10} - \chi^2$	$uLBP_W^{10 \times 10} - \chi^2$
1	96,29	89,63	87,74	90,29	89,14
2	95,06	88,73	87,66	89,30	87,66
3	95,55	89,06	88,40	89,63	88,15
4	95,88	85,93	86,43	89,63	88,32
5	94,81	90,29	88,81	88,56	86,67
Ortalama	95,52	88,73	87,81	89,49	87,98
σ^2	0,6	1,67	0,9	0,62	0,9

Yale B veri tabanında yapılan ikinci deneyde görüntüleri iyileştirmek amacıyla filtre uygulanmıştır (Nabatchian, 2011). Filtre uygulanan görüntülere ilk yapılan deneyler tekrar edilip, filtrenin tanıma oranındaki başarıyı gözlemlenmiştir.

Çizelge 4. 7. Yale B veri tabanında filtre uygulanmış $10 \times 10 = 100$ bölgeye ayrılıp $uLBP_{(8,1)}$ öznetelik çıkarımı uygulanan deneysel çalışmalar.

Deneyler	$F - uLBP - LRC$	$F - uLBP^{10 \times 10} - LRC$	$F - uLBP_W^{10 \times 10} - LRC$	$F - uLBP^{10 \times 10} - \chi^2$	$F - uLBP_W^{10 \times 10} - \chi^2$
1	97,36	35,69	52,79	93,33	91,28
2	96,95	35,77	54,11	91,85	89,8
3	96,13	31,00	47,69	91,85	88,4
4	96,62	36,10	45,64	90,70	89,47
5	96,13	46,05	57,31	91,61	90,46
Ortalama	96,64	36,92	51,51	91,87	89,88
σ^2	0,53	5,52	4,77	0,94	1,07

5.SONUÇLAR ve YORUMLAR

Bu tez çalışmasında; doku tanıma, yüz tanıma, cinsiyet belirleme, yaşın tanınması gibi birçok alanda kullanılan Yerel İkili Örüntüler (LBP) öznitelik çıkarım yöntemi kullanılmıştır. Sınıflandırıcı olarak alt uzay tanıma yöntemlerinden olan Doğrusal Regresyon Sınıflandırıcı (LRC) ve histogramların karşılaştırılmasında kullanılan Ki-kare (χ^2) testi kullanılmıştır.

Deneysel çalışmalar AR ve Genişletilmiş Yale B yüz veri tabanlarında test edilmiştir. Veri tabanlarındaki yüz görüntüleri yapılan bazı deneylerde bölgelere ayrılmıştır. Yüzdeki bazı bölgelerin, yüz ifadelerinden dolayı tanımaya daha fazla katkı sağladığını düşünerek, bölgelerin önem derecelerine göre ağırlıklandırmalar yapılmıştır.

AR veri tabanında yapılan $uLBP_{(8,1)}$ ve $LBP_{(8,1)}$ deneysel çalışmaları incelediğimizde LRC sınıflandırıcısının χ^2 istatistiğine göre daha başarılı olduğu görülmüştür. Deneysel çalışmalarda LBP öznitelik çıkarım yönetiminde kullanılan komşuluk sayısı ve örneklem yarıçapı değiştirildiğinde $uLBP_{(16,2)}$ 'nin başarımının $uLBP_{(8,1)}$ 'e göre daha fazla olduğu görülmüştür. Komşuluk sayısı ve örneklem yarıçapının artmasının tanıma oranını arttırdığı gözlemlenmiştir. Her ne kadar tanıma oranlarında artış gözlemlense de $uLBP_{(16,2)}$ kullanıldığında karşılaşılan hesapsal yük artışı göz önüne alındığında $uLBP_{(8,1)}$ komşuluk önerilmektedir. Yapılan diğer deneysel çalışmada LBP öznitelik çıkarım yöntemi yerine LRC alt uzay tabanlı sınıflandırma yöntemi kullanılmıştır. LRC yönteminde görüntülerin altuzaylara izdüşümleri alınarak öznitelikleri çıkarılıp, en yakın komşuluk kuralına göre sınıflandırılmaktadır. Bu şekilde elde edilen sonuçlara göre yüz görüntüleri bölgelere ayrıldığında, bölgelere ayrılmamış yüz görüntüsüne göre daha başarılı sonuçlar elde edilmiştir. Yapılan deneylerde eğitim ve test görüntüleri rastgele seçilen görüntülerden elde edilmiştir. $uLBP_{(8,1)}$ ve $LBP_{(8,1)}$ deneylerinde eğitim görüntüleri seçilerek tekrar edildiğinde tanıma başarım oranlarının arttığı görülmüştür.

Genişletilmiş Yale B veri tabanında filtresiz $uLBP_{(8,1)}$ ve filtreli $uLBP_{(8,1)}$ deneyleri gerçekleştirilmiştir. Uygulanan filtrede veri tabanında aydınlatma koşullarından etkilenen görüntülerin, aydınlatmadan kaynaklanan tanıma

problemini azaltması beklenmektedir. Yapılan deneysel çalışmalarda filtre uygulanan LRC sınıflandırıcısında başarı oranının düştüğü χ^2 istatistiğinde ise daha başarılı olduğu görülmüştür.

Yapılan deneyler sonucunda, LRC sınıflandırıcısı başarımının kullanılan veri tabanına göre değişkenlik gösterdiği, ancak χ^2 istatistiğinin kullanılan veriden bağımsız olarak yüksek başarımla sağladığı gözlemlenmiştir. Tanıma oranını arttırmak amacıyla gerçekleştirilen ağırlıklandırma işlemi sonucunda başarımla oranının düştüğü görülmüştür. İlerleyen çalışmalarda farklı ağırlıklandırma süreçlerinin izlenmesi ile χ^2 istatistiği performansının artırılabilirliği düşünülmektedir.

KAYNAKLAR

- Ahonen, T., Hadid A., Pietikainen, M. (2006). Face Description with Local Binary Patterns. IEEE Transactions On Pattern Analysis And Machine Intelligence, 28(12), 2037-2041
- Büyüköztürk, Ş. (2002) . Sosyal Bilimler İçin Veri Analizi El Kitabı. Pegem Akademi, Ankara.
- Comon, P. (1992). Independent component analysis, A new concept?. Signal Processing, France, 287-314.
- Delac, K., Grgic, M. (2004). A Survey Of Biometric Recognition Methods. 46th Internatiol Sysposium Electronics in Marine, 16(18), 184-193.
- ErgenB., Çalışkan A. (2011). Biyometrik Sistemler ve El Tabanlı Biyometrik Tanıma Karakteristikleri. 6 th International Advanced Technologies Symposium (IATS'11).
- Fairhust, M., Li, C., Costa-Abreu, M. Predictive biometrics: a review and analysis of predicting personal characteristics from biometric data. IET Biometrics.
- Filiz, S. (2012). Siber Güvenlikte Biyometrik Sistemler Ve Yüz Tanıma. Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara.
- Imran, M. A., Miah M. S. U., Rahman H. (2015). Face Recognition Using Eigenfaces. International Journal of Computer Applications, 118(5)
- Jia, H., Martinez, A.M. (2009). Support Vector Machines in Face Recognition with Occlusions.
- Kazak Çerçevik, N. (2018). Doku Tanımadaki Şekil Bilgisi Kullanarak Yeni Özniteliklerin Elde Edilmesi. Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Kazak, N., Koç M. (2016). Performance Analysis of Spiral Neighbourhood Topology Based Local. International Journal of Applied Mathematics, Electronics and Computers, 338-341.
- Kızrak, M. (2014). Local Binary Pattern Yöntemi İle Yüz İfadelerinin Tanınması. Şekil Tanıma Proje Raporu.
- Koç, M. (2012). New Subspace Approaches in Pattern Recognition. Doktora Tezi, Anadolu Üniveritesi, Fen Bilimleri Enstitüsü, Eskişehir.
- Köse, K. (2012). Korelasyon ve Regresyon Analizi. file.toraks.org.tr, (30.07.2019).
- Kuerban, S. (2018). Derin Öğrenmeye Dayalı El Sırtı Damar Tanıma Tekniğinin Geliştirilmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Kayseri.

KAYNAKLAR (Devam Ediyor)

- Kurbanov, O. (2018). Derin Sinir Ağları Kullanarak Parmak İzi Tanımada Yeni Yaklaşımlar. Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- Kurt, B., Nabiyev V. V., Bekiroğlu, Y. (2007). Yüz İfadelerinin Tanınması. www.emo.org.tr/ekler/a7dfe8c391c3a87_ek.pdf,(30.07.2019)
- Li, Z., Imai, J. (2010). Robust Face Recognition Using Block-Based Bag of Words. 2010 20th International Conference on Pattern Recognition (ICPR), 1285-12888.
- Lian, H., Lu, B.. (2006). Multi-view Gender Classification Using Local Binary Patterns and Support Vector Machines. International Symposium on Neural Networks , 17(6),202-209.
- Martinez, A.M. (1999). The AR face database. www2.ece.ohio-state.edu/aleix/ARdatabase, (30.07.2019)
- Martinez A.M., Kak, A.C. (2001). PCA versus LDA. IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(2), 228- 233.
- Nabatchian, A., Abdel-Raheem, E., Ahmadi, M. (2011). Illumination invariant feature extraction and mutual-information-based local matching for face recognition under illumination variation and occlusion. Pattern Recognition 44, 2576-2587.
- Naseem L., Togneri R., (2010). Bennamoun M., Linear Regression For Face Recognition. IEEE Trans. Pattern Analysis and Machine Intelligence. 29(1), 51-59.
- Nabiyev, V. V., Günay, A. (2011). LBP Yardımıyla Görüntüdeki Kişinin Yaşının Bulunması. Cankaya University Journal of Science and Engineering, 8(1), 27-41.
- Ojala, T., Pietikainen M., Harwood D. (1996). A Comparative Study Of Texture Measures With Classification Based On Feature Distributions. Pattern Recognition, 29(1), 51-59.
- Ojala, T., Pietikainen, M., Maenpaä, T. (2002). Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. IEEE Transactions On Pattern Analysis And Machine Intelligence, 24(7), 971-987.
- Özkaynak, E. (2013). Paralel Programlama İle Ses Tanıma İşleminin Gerçekleştirilmesi. Yüksek Lisans Tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük.
- Ping- Han L., Wang, Y.W., Yang, M.H., Hsu, J., Hung, Y.P. (2006). Distinctive Personal Traits for Face Recognition Under Occlusion. IEEE International Conference on Systems, 4202-4207.

KAYNAKLAR (Devam Ediyor)

- Parlakıyıldız, Ş. (2014). Yapay Sinir Ağları Kullanılarak Parmak İzi Tanıma Ve Sınıflandırma. Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Sánchez López, L. (2010). Local Binary Patterns applied to Face Detection. Final Research Project. Signal Theory & Communication Department
- Shan, C., Gong, S.,McOwan P.W. (2009). Facial Expression Recognition Based On Local Binary Patterns: A Comprehensive Study. Image and Vision Computing 27, 803-816.
- Sisnelioğlu, S. (2014). Matematiksel Biçimbilim İle Çevrim-Dışı İmza Tanıma. Yüksek Lisans Tezi, Okan Üniversitesi, Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul.
- Şan, S. (2013). Parmak Damar Tanıma Teknolojisi. Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Tan, X., Chen, S., Zhou, Z.H., Liu, J. (2009). Face Recognition Under Occlusions and Variant Expressions With Partial Similarity. IEEE Transactions on Information Forensics and Security, 4(2), 217-230.
- Yıldız, F., Baykan N. A. (2011). Çapraz İlişki Metoduyla İris Tanıma. Selçuk-Teknik Dergisi, 10(1)
- Weisburg, S. (2005). Applied Linear Regression. America,134.
- Zhao, W., Chellappa, R., Phillips, P.J., Rosenfeld A. (2003). Face Recognition: A Literature Survey, ACM Computing Surveys, 35(4), 399-458.

ÖZ GEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Şulenur EROL
Doğum Yeri ve Tarihi : Fatsa – 02.11.1991



Eğitim Durumu

Lisans Öğrenimi : Elektrik Elektronik Mühendisliği

İş Deneyimi

Stajlar : UEDAŞ, Sentez Mühendislik,
Birfen Elektrik-Elektronik

Çalıştığı Kurumlar : Taner Yapı Denetim Ltd. Şti., İzmit Belediyesi

İletişim

Adres : Fatih Sultan Mehmet Mah. Uluşık Cad.
No:7/59 Kartepe/Kocaeli
E-Posta Adresi : sulenurergul@gmail.com

Akademik Çalışmaları

Tarih:...../...../.....