



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



K-TDA SÖZLÜK ÖĞRENMESİ İLE
GÖRÜNTÜ ZENGİNLEŞTİREREK İRİS
TANIMA

Ali BİRCAN

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ali BİRCAN tarafından hazırlanan “K-TDA Sözlük Öğrenmesi ile Görüntü Zenginleştirerek İris Tanıma” adlı tez çalışması 24 / 06 / 2021 tarihinde aşağıdaki jüri tarafından OY BİRLİĞİ ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Halife KODAZ

Danışman

Dr. Öğr. Üyesi Nurdan BAYKAN

Üye

Dr. Öğr. Üyesi Uğur ERKAN

İmza / Kabul

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Ali BİRCAN

Tarih: Haziran – 2021

ÖZET

YÜKSEK LİSANS TEZİ

K-TDA SÖZLÜK ÖĞRENMESİ İLE GÖRÜNTÜ ZENGİNLEŞTİREREK İRİS TANIMA

Ali BİRCAN

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Nurdan BAYKAN

2021, 102 Sayfa

Jüri

Prof. Dr. Halife KODAZ
Dr. Öğr. Üyesi Nurdan BAYKAN
Dr. Öğr. Üyesi Uğur ERKAN

Biyometri, kullanıcının fiziksel ve davranışsal özelliklerini tanıyarak kimlik saptamak üzere geliştirilmiş bilgisayar kontrollü, akıllı sistemler için kullanılan genel bir terimdir. Bu tez çalışmasında, biyometrik sistemlerin bir alt dalı olan iris tanıma yöntemi ile kimlik doğrulama sistemi gerçekleştirilmiştir. İris tanıma sistemleri birbirini takip eden aşamalardan oluşmaktadır. Tez kapsamında Casia İris veritabanından alınan görüntüler kullanılmıştır. Kullanılan yöntemde iris resmi veritabanından alınmakta, ortanca filtresi uygulanarak bulanıklaştırılmaktadır. Daha sonra gözbebeği sınırları tespit edilmiştir. Takip eden aşamada iris bölgesi Dairesel Hough Dönüşümü Yöntemi ile belirlenmekte ve iris bölgesi görüntünün geri kalanından ayrılmaktadır. Daha sonra Kartezyen koordinattan polar koordinata geçiş yapılmıştır. Bu sayede iris görüntüsü matris formatında dikdörtgen hale dönüştürülmüştür. Polar koordinata dönüştürülmüş tüm görüntüler 256x64 piksel olarak yeniden boyutlandırılmış ve tüm görüntüler standart hale getirilmiştir. Önilem aşamalarından geçerek, iki boyutlu matris formatında standart boyutlara getirilen görüntüler normalize edilmiş ve daha sonra ayrılan iris bölgesi üzerinden K-Tekil Değer Ayrıştırma (K-TDA) sözlük öğrenme yöntemi ile görüntü zenginleştirme yapılarak irise ait ayırt edici özelliklerin belirginleştirilmesi sağlanmıştır. Bu sayede elde edilen özellik vektörleri ile iris görüntüleri üzerinde Yapısal Benzerlik İndeksi (YBI), Hamming Uzaklığı (HU), Öklid Uzaklığı (ÖU) ve Ortalama Karesel Hata (OKH) kullanılarak karşılaştırma yapılmakta, doğrulama ve tanılama sistemleri oluşturulmaktadır. Segmentasyon hataları, iris tanıma başarımlar yüzdeleri, hata yüzdeleri literatür ile karşılaştırmalı olarak incelenmiş, önerilen yöntem literatürdeki yöntemlerle rekabetçi başarımlar sunmuştur. Tez kapsamında geliştirilen ve Öklid Uzaklığı kullanan yöntem %99.86 başarı göstermiştir. Hatalı kabul oranı %0 olarak gerçekleşirken, hatalı reddetme oranı 0.0014 olmuştur.

Anahtar Kelimeler: Biyometrik sistemler, görüntü işleme, iris tanıma, sözlük öğrenmesi.

ABSTRACT

MS THESIS

IRIS RECOGNITION BASED ON IMAGE ENHANCEMENT USING K-SVD DICTIONARY LEARNING

Ali BİRCAN

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Asst. Prof. Dr. Nurdan BAYKAN

2021, 102 Pages

**Jury
Prof. Dr. Halife KODAZ
Asst. Prof. Dr. Nurdan BAYKAN
Asst. Prof. Dr. Uğur ERKAN**

Biometrics is a general term used for computer-controlled, automated and smart systems developed to identify the user by recognizing the physical and behavioral characteristics. In this thesis, an identity verification system implemented with iris recognition method, which is a sub-branch of biometric systems. Iris recognition systems consist of successive stages. Images taken from Casia Iris database were used in the scope of the thesis. In the method, the iris picture is taken from the database and blurred by applying the median filter. Then the pupil boundaries are determined. In the next step, the iris region is determined by the Circular Hough Transform Method and the iris region is separated from the rest of the image. Later, a transition was made from Cartesian coordinate to polar coordinate. In this way, the iris image is transformed into a rectangular form in matrix format. All images converted to polar coordinates were resized as 256x64 pixels and all images were standardized. After going through the preprocessing stages, the images brought to standard dimensions in two-dimensional matrix format were normalized and then the distinctive features of the iris were clarified by enriching the images with the K-Singular Value Decomposition (K-SVD) dictionary learning method over the separated iris region. By this means, comparison is made on iris images with the feature vectors obtained by using Structural Similarity Analysis (SSIM), Hamming Distance (HD), Euclidian Distance (ED) and Mean Squared Error (MSE) and verification and diagnosis systems are established. Segmentation errors, iris recognition success percentages and error percentages were examined in comparison with the literature, and the proposed method presented competitive successes with the methods in the literature. The method developed within the scope of the thesis using Euclidean Distance has shown 99.86% success. While the false acceptance rate was 0%, the false rejection rate was 0.0014.

Keywords: Biometric systems, image processing, iris recognition, dictionary learning.

ÖNSÖZ

Biyometri uygulamalarının amacı kişilerin kimlik tespiti için yanlarında herhangi bir şey taşımaları ya da bilgiyi hatırlamaları yerine; kişinin kopyalanması ya da taklit edilmesi imkânsız olan kendine ait özelliklerini kullanmalarını sağlamaktır.

Bu tez kapsamında biyometrik sistemlerin bir alt dalı olan iris tanıma sistemi üzerine çalışılmıştır. İris tanıma ile kimlik doğrulama yapan bir sistem için sözlük öğrenmesi ile özellik çıkarılarak tanıma işlemi gerçekleştirilmiştir. Çalışmada, hedef veri tabanı üzerinde sözlük öğrenmesi ile beraber literatürdeki iris tanıma sistemleri ile karşılaştırılmalı sonuçlar sunulmuştur.

Bu çalışmada değerli yardımlarını esirgemeyen ve yol gösteren saygıdeğer danışman hocam Dr. Öğr. Üyesi Nurdan BAYKAN'a, birlikte çalışmaktan her zaman keyif aldığım, her türlü sorun için değerli önerilerini esirgemeyen ve birlikte çalışmaktan onur duyduğum Doç. Dr. Ömer Kaan BAYKAN'a,

Proje süresince en büyük destekçim olan sevgili eşime, oğluma ve aileme,

Sonsuz teşekkürlerimi sunuyorum.

Ali BİRCAN
KONYA-2021

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	iv
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	2
1.2. Tezin Önemi	3
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM.....	13
3.1 Biyometrik Sistemler	13
3.1.1. Parmak İzi Tanıma.....	15
3.1.2. Ses Tanıma.....	16
3.1.3. Yüz Tanıma.....	18
3.2. İris Tanıma Sistemleri.....	19
3.3. Makine Öğrenmesi.....	23
3.4. Sözlük Öğrenmesi.....	24
3.4.1. Seyrek Gösterim (Sparse Coding) Kavramı	24
3.4.2. Seyrek Gösterimde Kullanılan Norm İfadeler	27
3.4.3. Farklı Norm İfadeleriyle Seyrek Gösterim Problemi	28
3.4.4. Seyrek Gösterimde Kullanılan Takip Algoritmaları.....	29
3.4.5. Sözlük Öğrenme İle Alakalı Temel Kavramlar	31
3.4.6. Sözlük Öğrenme	38
3.4.7. K-TDA Sözlük Öğrenmesi	40
3.4.8. Sözlük Öğrenme ile Görüntü İşleme Uygulamaları	47
3.5. Görüntü İşleme	47
3.6. Sınıflandırma	54
3.7. Python Programlama Dili ve OpenCV	58
4. ÖNERİLEN YÖNTEM	60
4.1. Kullanılan Veriseti.....	60
4.2. K-TDA ile İris Özelliklerinin Vurgulanması.....	62
5. DENEYSEL SONUÇLAR	69
6. SONUÇLAR VE ÖNERİLER	71
6.1. Sonuçlar	72
6.2. Öneriler	73
6.3. Tartışma	75

KAYNAKLAR	76
EKLER	88



SİMGELER VE KISALTMALAR

Simgeler

$a(x, y)$	: (x, y) noktasındaki piksel değeri
bit	: Bilgisayarın en küçük dosya birimi
e	: Euler sabiti
$I(p, \Phi)$	: Boyutsuz bir kutupsal koordinat sistemindeki işlenmemiş iris görüntüsü
$I(r, \theta)$	: Standartlaştırılmış kutupsal koordinat sistemindeki (r, θ) koordinatlarındaki piksel değeri
P_i	: Pi Sayısı
x, y	: x, y koordinatı

Kısaltmalar

1-b	: 1 boyutlu
2-b	: 2 boyutlu
ADMM	: Alternating direction method of multipliers
API	: Uygulama programlama ara yüzü.
BMP	: Bitmap Image File format
CAMFEM	: Complex Architecture, Multiple Feature Extraction Architecture
CASFEM	: Complex Architecture, Single Feature Extraction Method
CCD	: Charge-Coupled device
DBSCAN	: Density-based spatial clustering of applications with noise
DDPG	: Deep Deterministic Policy Gradients
DFT	: Discrete Fourier Transform
DHD	: Dairesel Hough Dönüşümü
DQN	: Deep Q Networks
FAR	: False Acceptance Rate
FFT	: Fast Fourier Transform
FISTA	: Fast Iterative Shrinkage-Thresholding Algorithm
FR	: False Rejection
GUI	: Graphical User Interface
HKO	: Hatalı Kabul Oranı
HM	: Hamming Mesafesi
HRO	: Hybrid Rice Optimization
ICA	: Independent Component Analysis
KLD	: Kinematics and Dynamics Library

K-NN	: K-Nearest Neighbours
K-TDA	: K-Tekil Değer Ayırıştırması
LBP	: Local Binary Pattern
LVQ	: Learning Vector Quantization
MLSDL	: Multi-Spectral Low-Rank Structured Dictionary Learning
NIR	: Near InfraRed
NN	: Neural Networks
PCA	: Principal Component Analysis
PDDP	: Principal Direction Divisive Partitioning
PIN	: Personal Identification Number
PPO	: Proximal Policy Optimization
PSO	: Parçacık Sürü Optimizasyonu
RGB	: Red Green Blue (Renk Uzayı)
S-DSLR	: Supervised dictionary learning and sparse representation
SFDL	: Simultaneous Feature and Dictionary Learning
SIMFEM	: Single in-line Multiple-steps Feature Extraction Method
SISFEM	: Single in-line single Feature Extraction Method
SimCO	: Simultaneous Codeword Optimization
SVDL	: Sparse Variation Dictionary Learning
vb	: ve benzeri
ve ark.	: ve arkadaşları
YSA	: Yapay sinir ağları

* Tez kapsamında sayılar ve sayı birimleri SI (The International System of Units – Fransızca Le Système International d’Unités) sistemine uygun olarak verilmiştir.

1. GİRİŞ

Biyometri, kişilerin kendilerine has fizyolojik özelliklerini ölçen ve bu özellikleri kullanarak teşhis ve doğrulama uygulamalarında kullanılan genel bir tekniktir. Biyometri uygulamalarının amacı, kişilerin kimlik tespiti için yanlarında herhangi bir şey taşımaları ya da bilgiyi hatırlamaları yerine, kişinin kopyalanması ya da taklit edilmesi imkânsız olan kendine ait özelliklerini kullanmalarını sağlamaktır.

İris, gözün ön kısmında bulunan ve lifli dokudan oluşan renkli zar şeklindeki tabakaya verilen addır. İriste 250'den fazla görsel karakteristik özellik bulunmaktadır (Sturm ve Larsson, 2009). Bu karakteristik özellikler daireler, benekler, çizgiler gibi görüntü işlemede kullanılabilecek belirleyici şekillerdir. Embriyo olarak anne karnındayken oluşan iris, insanın ölümüne kadar değişmez. Bu nedenle kimlik tanıma uygulamalarında kullanılması uygundur (Sturm & Larsson, 2009).

Dijital görüntü işleme iki ya da üç boyutlu bir görüntünün bilgisayar aracılığıyla işlenmesidir. Durağan görüntüler üzerinde işlem yapılabileceği gibi, video ve animasyonlar üzerinde de işlemler yapılabilir. Dijital görüntü işleme teknikleri sayesinde görüntü iyileştirme, görüntü sıkıştırma, biyometrik tanıma, otomatik yüz tanıma, araç takibi, obje veya nesne sınıflandırma gibi işlemler yapılabilmektedir.

İris tanıma sistemleri, tanılama ve doğrulama yapan sistemlerdir. Bunun için çeşitli önışlem teknikleri (Gauss bulanıklaştırması, kenar bulma teknikleri vb.) ile irisin lokalizasyonu yapıp, yine bilgisayarla görme algoritmaları (Gabor filtreleri, HOG (Histogram of Oriented Gradients) özellikleri vb.) ile resim üzerindeki öznelilikler çıkarılmaktadır. Son aşamada ise çeşitli makine öğrenmesi ve karşılaştırma yöntemleri kullanılarak (Yapay sinir ağları, Hamming uzaklığı vb.) doğrulama ve tanılama yapılmaktadır (Daugman, 2004).

Kullanılabilirlik, mevcut iris tanıma sistemlerinin karşılaştığı en büyük problemlerden biridir. Kullanıcı kimlik doğrulaması için uzun menzilli iris görüntüsü edinme sistemleri geliştirme eğilimi son dönemde artmıştır. Bununla birlikte, uzaktan yakalanan iris görüntüleri, geleneksel yakın plan iris görüntülerinden daha zorlayıcıdır. Kamusal alanda uzun menzilli iris görüntü verilerinin olmaması, yeni nesil iris tanıma sistemlerinin araştırılmasını ve geliştirilmesini zorlaştırmaktadır. Bu nedenle veri alımı ya da yeni teknolojiler kullanılarak daha performanslı iris tanıma sistemlerinin geliştirilmesi üzerine çalışmalar yapılmaktadır.

İris tanıma sistemlerinde, diğer biyometrik sistemler gibi istatistik yöntemler ve makine öğrenmesi yöntemleri kullanılmaktadır. Ayrıca son yıllarda “sözlük öğrenme” (dictionary learning) de biyometrik sistemlerde kullanılmaya başlanmıştır.

Sözlük öğrenme, seyrek gösterimi (sparse representation) kullanan bir makine öğrenmesi yöntemidir. Seyrek gösterim, sinyallerin bir dönüşüm operatörü ya da bir sözlük aracılığıyla temsilidir. Ayrık Kosinüs Dönüşümü (DCT-Discrete Cosinus Transform) ve Dalgacık Dönüşümü (WT-Wavelet Transform) gibi, dönüşüm matrisinin boyutu sinyalin boyutu ile aynı ise bu dönüşümlere “tam” (complete) adı verilir. Dönüşüm matrisinin işaret uzayından daha fazla sayıda sütun içerdiği dönüşüme ise “aşırı tam” (overcomplete) dönüşümler denilmektedir. Sinyallerin seyrek gösteriminde kullanılan bu dönüşüm matrisleri “sözlük” (dictionary) ya da “operatör” (operator) olarak isimlendirilirler (Azizoğlu, 2017).

Yapılan tez çalışmasında, iris tanıma sisteminin başarısını arttıran ve hızlı bir şekilde işlem yapılabilmesine olanak sağlayan yeni bir sözlük tabanlı yöntem önerilmiştir. Geliştirilen yöntem, iris görüntüsüne dairesel Hough dönüşümü uygulayıp iris çevresini belirlemekte ve bunu görüntüden çıkarmaktadır. Sonraki aşamada çıkarılan dairesel iris görüntüsü dikdörtgen bir şekle dönüştürülmektedir. Bir sonraki aşamada ise farklı sözlük öğrenme metodları (K-TDA ve Çevrimiçi (Online)) kullanılarak özellik vektörleri zenginleştirilmektedir. Daha sonra ise Yapısal Benzerlik İndeksi (YBİ) (SSIM-Structred Similartiy Index Measurement) kullanılarak veritabanındaki diğer görüntüler ile karşılaştırılmıştır. Elde edilen sonuçlar, önerilen yöntemin iris tanıma sistemlerinde başarılı bir şekilde kullanılabileceğini ortaya koymuştur.

1.1. Tezin Amacı

Sözlük öğrenmesi genel olarak veriler üzerinde özellik çıkarma, seyrekleştirme veya birleştirme için kullanılan, her biri belli miktarda atom içeren sözlükler kullanılarak yapılan bir makine öğrenmesi çeşididir. Yapılan tez çalışmasında, 1980-2020 arası iris tanıma sistemleri incelenerek, sözlük öğrenmesi tabanlı bir iris tanıma sisteminin geliştirilmesi amaçlanmaktadır. Çalışma kapsamında, sözlük öğrenmenin seyrekliği destekleyen yapısı ile iristen çıkarılacak özelliklerin sınıflandırılması amaçlanmıştır. Bu sayede sözlük öğrenme kullanılarak modern bir iris tanıma sistemi ve sözlük öğrenmesinin iris tanıma alanında nasıl kullanılacağı ile alakalı bir çerçeve

ortaya konulmuştur. Ayrıca yapılan detaylı kaynak araştırması ile iris tanıma ve sözlük öğrenme kaynaklarıyla Türkçe literatüre katkı sunmak amaçlanmaktadır.

1.2. Tezin Önemi

İris tanıma yöntemleri, genellikle yüzlerce denekle birlikte orta uzaklıktan yakalanan iris görüntü veritabanları üzerinde geliştirilmektedir. İris tanıma güvenilir ve farklı alanlarda (askeri, ticari, kişisel vb.) kullanılan etkinliği kanıtlanmış bir doğrulama ve tanıma sistemidir. Bununla birlikte, gerçek dünya uygulamalarında giderek daha büyük ölçekli iris tanıma sistemleri kullanılmaktadır. Ancak, büyük ölçekli iris görüntü veritabanlarının sınıflandırılması ve indekslenmesinde pek çok yeni sorunla karşılaşmıştır.

İris tanıma işlemi için farklı yöntemler kullanılabildiği gibi makine öğrenmesi literatürde oldukça fazla yer almaktadır. Türkçe literatürde biyometrik çalışmalar yaygın olsa da, bugüne kadar iris tanıma üzerine sınırlı sayıda çalışma yapılmış ve yapılan bu çalışmalarda ise daha çok görüntü işleme ile iris tanıma yapılmıştır (Akhan, 2004; Gürkan, 2005; Şahin, 2016). Ancak bu çalışmalarda iris resminin özelliklerinin depolanması ile ilgili çalışma bulunmamaktadır. Bunun yanında ilgili çalışmaların tamamında iris tanıma sistemi önerilmemiş, yalnızca hata düzeltme veya analiz yapılmıştır.

Sözlük öğrenme, verimliliği ve kullanışlılığı farklı alanlarda (sınıflandırma, tanılama, görüntü işleme vb.) kanıtlanmış (Gangeh ve ark., 2015; Dumitrescu ve Irofti, 2018; Garcia-Cardona ve ark., 2018) bir yöntemdir. Son yıllarda çalışma alanı artan sözlük öğrenme, sinyal işleme ve makine öğrenmenin bir dalıdır ve eğitim verilerinin seyrek bir sunumunu (sparse representation) “sözlük” (dictionary) adı verilen bir yapıda bulmayı amaçlamaktadır. Literatürde sözlük öğrenme tabanlı farklı iris tanıma çalışmaları bulunmaktadır (Qiu ve ark., 2007; Song ve ark., 2014). Yapılan tez çalışmasında, iris tanıma sisteminin geliştirilmesi, depolama için uygun bir modelin önerilmesi ve hata düzeltmeleri ile birlikte bütünlük bir yaklaşım ortaya konulmuştur. Bu sayede yapılan tez çalışması sonucunda ortaya konan sistem, ticari ve akademik olarak kullanılabilecek nitelikte olması ile önem arz etmektedir. Ayrıca, yapılan tez çalışması sayesinde sözlük öğrenme ile iris tanıma alanında Türkçe bir çalışma da ortaya konmuştur.

2. KAYNAK ARAŞTIRMASI

İris tanıma sistemlerinin tanıma amaçlı olarak kullanılabileceği düşüncesini, 19. yüzyılın başlarında ilk ortaya atan kişi Fransız göz doktoru Alphonse Bertillon'dur. Ancak bu düşünce onun zamanında uygulamaya geçirilememiştir (Boles ve ark., 1998). Daha sonra, 1987 yılında Alan Safir ve Leonard Flom iris biyometrik sistemde kullanılması düşüncesinin patentini almışlardır. Kişisel tanımlamada iris tanıma sisteminin ilk kullanımına Paris ceza sisteminde rastlanmıştır. Daha sonraları, Flom ve Safir tarafından otomatik iris tanıma fikri ortaya atılmıştır. Ancak, bu kişilerin çalışan bir sistem tasarladıkları görülmemiştir. Gerçek anlamda ilk otomatik iris tanıma sistemi Kaliforniya Los Alamos Ulusal laboratuvarında geliştirilmiştir. Bunu takip eden iki araştırma grubu, prototip bir iris tanıma sistemi geliştirmiş ve sistemi çalıştırıp test etmişlerdir. Bu sistemde, yüzlerce iris görüntüsü içeren farklı veri tabanları üzerinde çalışmalar yapılmış ve umut verici sonuçlar elde edilmiştir (Flom ve ark., 1987; Bulut, 2011).

1990'lı yıllardan beri iris tanıma alanında büyük ilerleme kaydedilmesine karşın, iris tanıma uygulamalarının hızla büyümesi, kullanılabilirlik (sistemin kurulumu, görüntülerin elde edilebilirlik koşulları, kullanım kolaylığı vb.) ve ölçeklenebilirlik (bir sistemin artan kapasiteden kaynaklı problemlerle, performanstan feragat etmeden başedebileceğini ifade eden terim) gibi iki zorluğa açıkça vurgu yapmıştır. Kullanılabilirlik, mevcut iris tanıma sistemlerinin karşılaştığı en büyük problemlerden biridir. Kullanıcı kimlik doğrulaması için uzun menzilli iris görüntüsü edinme sistemleri geliştirme eğilimi son dönemde artmıştır. Bununla birlikte, uzaktan yakalanan iris görüntüleri, geleneksel yakın plan iris görüntülerinden daha zorlayıcıdır. Kamusal alanda uzun menzilli iris görüntü verilerinin olmaması, yeni nesil iris tanıma sistemlerinin araştırılmasını ve geliştirilmesini zorlaştırmaktadır. Şu anki çoğu iris tanıma yöntemleri, genellikle yüzlerce denekle birlikte orta uzaklıktan yakalanan iris görüntü veri tabanları üzerinde geliştirilmektedir. Bununla birlikte, gerçek dünya uygulamalarında giderek daha büyük ölçekli iris tanıma sistemleri kullanılmaktadır. Büyük ölçekli iris görüntü veri tabanlarının sınıflandırılması ve indekslenmesinde pek çok yeni sorunla karşılaşmıştır. Bu nedenle ölçeklenebilirlik, iris tanımada bir başka zorlu sorundur (Qiu, ve ark., 2007; Mani ve Nadeski, 2015; Kuehlkamp ve Bowyer, 2018).

Daugman, bir insanı tanımlamak için benzersiz bir şekilde irisin biyometrik analizini yapan operasyonel bir yöntem için bir patent almıştır (Daugman, 2004). Daugman, 1993 ve 1994'teki o güne kadarki iris tanıma faaliyetlerin çoğunun temelini oluşturan yeni bir iris tanıma sistemi sunmuştur. Bu sistemde, bir "İntegro diferansiyel operatörü" yardımı ile iris, iç pupiller sınırı ve dış sklera sınırını bölmeden önce lokalize edip, Gabor filtreleri ile özellikler çıkartılmıştır. Çalışmada Rubber Sheet normalizasyonu Daugman tarafından önerilmiştir. Bu metot lineer olarak Kartezyen koordinatları polar koordinatlara haritalamaktadır. 2048 bitlik iris kodlarıyla bit-bazlı (EX-OR) karşılaştırma yaparak benzerlik oranı hesaplanmıştır. Gözbebeği genişlemesi, boyut değişikliği ve görüntü içinde değişikliklere karşı iyi sonuçlar vermektedir. Bu metodun dezavantajı iris görüntüsünün döndürmeye olan hassasiyetidir. Gözbebeği yarıçapı ve iris yarıçapı farklı olduğundan, normalizasyon boş pikselleri doldurmak için bazı pikselleri tekrarlamaktadır (Daugman, 1993; Daugman, 1994).

Wildes, 1997'de farklı bir yaklaşım denemiştir. Bu yöntemde iç ve dış iris sınırı, bir değişim tabanlı ikili kenar haritasının (map) ve ardından dairesel Hough dönüşümünün yardımıyla hesaplanmıştır. Wildes, segmentasyon tekniği ve normalleştirilmiş korelasyon eşleştirme tekniği için iki ayrı patent almıştır (Wildes ve ark., 1994; Wildes, 1997).

Daugman daha sonra 2004'te daha gelişmiş bir yaklaşım önermiştir (Daugman, 2004). Bu model, bir insan gözünün iris görüntüsünü alırken ortaya çıkan gürültü bozuklukları ile çalışmak üzere tasarlanmıştır.

Daugman'ın yaklaşımını baz alan tam anlamıyla aktif çalışan sistem, bilgisayarla görme teknikleriyle iris edinimi yapmaktadır ve Hanna ve ark., tarafından sunulmuştur (Patent Sayı US6714665B1, 2004; Hanna ve ark., 2004). Daugman daha sonra 2007'de segmentasyon aşamasında, eksen dışı iris görüntülerinin kullanımında yardımcı olacak yeni bir görüntü işleme algoritması önermiştir.

Daugman'ın 1993'te önerdiği metodundaki (Daugman, 1993) problemin çözümü için Shamsi ve Rasouli tarafından trapezoidal (ikizkenar yamuk) yaklaşımı 2011 yılında önerilmiştir. İris görüntüsü eş merkezli disklere bölünmüş, sonra açılmıştır. Birebir haritalama olduğu için piksel tekrarına gerek yoktur. Normalizasyon görüntüsü ikizkenar yamuğa benzemektedir. Bu sayede yanlış doğrulama oranı düşmektedir (Shamsi ve Rasouli, 2011).

Gözün anatomisi gözlenebilen özellikler açısından (kılcal damarlar, gözbebeği, iris vb.) oldukça zengindir. Özellik çıkarmanın başarısı irisi farklılaştıran desensel

özelliklerin uygun bir şekilde temsil edilmesinde yatmaktadır. Bu amaçla iris segmentasyonu için farklı çalışmalar yapılmıştır (Kong ve ark., 2001). Huang ve ark., başlangıçta, görüntü kenarını tanımlamak ve daha sonra sklera veya dış sınırı bulmak için maksimum daireyi oylamak için bir orta filtre (median) ve ardından Canny operatörü tarafından bölümlendirmenin gerçekleştirildiği etkili bir iris tanıma tekniğini tarif etmişlerdir (Huang ve ark., 2002).

Lili ve Mei; histogram özelliklerini kullanarak gözbebeğinin merkezini bulmuşlar ve en küçük kareler metodu ile eğri uydurma (curve-fitting) kullanarak iris sınırlarının bulunmasını optimize etmişlerdir (Lili ve Mei, 2005).

2005'te yapılan bir diğer çalışmada Öklid uzaklığı, Hamming uzaklığı ve benzerlik fonksiyonu ile iris sınıflandırma yapan hibrit bir metodun analizi yapılmıştır. Hamming uzaklığının daha iyi çalıştığı görülmüştür (Sanchez-Avila ve Sanchez-Reillo, 2005).

Proença ve ark. (Proença ve ark., 2006) kooperatif olmayan iris görüntüleri için önce iris'den özelliklerin çıkarılması ve ardından bulanık kümeleme algoritması uygulanarak daha iyi bir segmentasyon algoritması sunmuştur. Daha sonra Ross ve Shah, (Ross ve Shah, 2006)'da 2 boyutlu medyan filtreleri segmentasyon aşamasında kullanıp, anizotropik difüzyon ile görüntü zenginleştirme uygularken; 2008'de Ng ve ark., farklı bir segmentasyon yöntemi önermişlerdir (Ng ve ark., 2008).

İris alanlarını bulmak için iki dairesel kenar bulma operatörü ve renk bilgisi kullanımı Jeong ve ark. tarafından gösterilmiştir. Adaboost tekniği ise ikincil segmentasyon hatalarının giderilmesi amacıyla kullanılmıştır (Jeong ve ark., 2010).

Gerçek zamanlı uygulamalarda iris resminin elde edilmesi ideal olmayan ortamlarda gerçekleşmektedir. Bu gibi durumlarda Pundlik ve ark., doku, yoğunluk ve geometri gibi bilgiler ile irisin segmentasyonunu yapmışlardır. Bu sayede, göz kapakları ve kirpik gibi engelleri daha keskin bir şekilde elemine etmişlerdir (Pundlik ve ark., 2010). Daha sonra, Tan ve ark., gürültülü iris tanıma operasyonlarında yüksek başarı elde eden bir algoritma önermişlerdir. Önerilen metot üç aşamadan oluşmaktadır. Engellerle irisin ayrılması için bir kümeleme şablonu kullanılmış, daha sonra sınırların belirlenmesi, kirpik ve şekil düzensizliklerinin giderilmesi için 1B filtre kullanılmıştır. Son olarak tekrardan kalan kirpik ve gölge engelleri için yoğunluk istatistikleri kullanılmıştır (Tan ve ark., 2010).

S. Zhou ve ark. (Zhou ve ark., 2013)'de yeni bir kod eşleştirme tekniği önerilmiştir. Segmentasyonda, iris sınırını lokalize etmek için histogram analizi ve

morfolojik işlem yapıldıktan sonra dış sınırın, pupiller sınırının iki kat büyüklüğüne sahip olduğu kabul edilmiş ve göz kapaklarının üst ve alt kısımlarını tespit etmek ve kaldırmak için Canny kenar bulma operatörü ardından polinom eğrisi uydurma algoritması kullanılmıştır.

Keskin eşikleme yerine, adaptif eşikleme Mehrotra ve ark. tarafından aydınlatmadan kaynaklanan segmentasyon hatalarının düzeltilmesi için kullanılmıştır. Daha sonra iris yarıçapının hesaplanması için kenar haritalama (edge-mapping) kullanılmış, belli sayıda iterasyon sonrasında ise iris yarıçapı bulunmuştur (Mehrotra ve ark., 2013)'de yapılan ve kenar haritalama kullanan bir diğer çalışmada ise, Dairesel Hough dönüşümünün ardından K-ortalama kümeleme ve kenar haritalama yöntemlerini kullanılmıştır (Sahmoud ve Abuhaiba, 2013).

Shannon'un teorisi (Rioul ve Magossi, 2014) ve uzaklık parametreleri ile karşıt entropi (cross-entropy) tabanlı kümelemenin segmentasyonda kullanımı Misztal ve ark., tarafından incelenmiştir. Keyfi (arbitrary) gauss fonksiyonlarıyla hesaplanan entropi iris ve gözbebeğini ayırmak için kullanılmıştır. Uygun uzaklık parametreleri ile engelleri (gözkapağı, kirpik vs.) kaldırmaya çalışmışlardır (Misztal ve ark., 2015).

Lim ve ark. bir CCD kamera yardımıyla uzak mesafeden göz görüntüleri elde etmiş ve aydınlatma nedeniyle ortaya çıkan yansıma etkisini en aza indirmek için, çevreleyen ışıklar için iki halojen lamba düzenlenmiştir (Lim ve ark., 2001).

Optimum sayıda özellik seçimi ile tüm özelliklerin kullanıldığı senaryolar kadar tanılama başarısı elde edilmesi mümkündür. Özellik seçimi, bu optimum sayıda özelliğin seçimi işlemidir. Bu sayede hem zaman hem de hesaplama karmaşıklığı azaltılarak tatmin edici sonuçlara ulaşılmaktadır. Hesaplama ve zaman karmaşıklığının azaltılması tanılama işleminin de hızını arttırmaktadır (Sahu ve ark., 2018). Özellik vektörleri çıkarma işlemini frekans alanında dalgacık dönüşümleri, eğrisel yaklaşımlar, enerji toplam tabanlı olanlar, SIFT tabanlı özellikler, SURF tabanlı özellikler gibi farklı algoritmalar ile yapılmıştır.

Boles ve ark., bir iris görüntüsünü bölümlere ayırmak ve normalize bir iris imzası (signature) elde etmek ve sanal daire analizi yapmak için dairesel kenar algılama tekniğini kullanmışlardır. Bu çalışma, frekans alanında iris imzasından çıkarmak için 1-b sinyallerinde "Wavelet dönüşümleri" yapan ilk çalışmadır (Boles ve ark., 1998). Frekans alanındaki çalışmalar daha sonra da devam etmiştir. Daugman, 1994'deki araştırmalarının ardından 2007'de iris sınırlarını yaklaşık olarak bulmak için Fourier katsayılarını kullanmıştır. Cui ve Ark., gözbebeğini bulmak için dalgacık

dönüşümündeki düşük frekanslı bileşenleri kullanmışlardır. İris sınırları diferansiyele integral operatör kullanılarak tespit edilmiştir (Cui ve ark., 2004; Monro ve ark., 2007). Hough dönüşümünün iris görüntüsünü gözden ayırmak için kullanıldığı ve 4'lü yakın komşuluk yönteminin iki-doğrusal enterpolasyonu kullanılarak dikdörtgen bir görüntü dizisine normalleştirildiği bir iris tanıma algoritması tasarlamıştır. Daha sonra Fourier uzamsal yoğunluğunu kullanan enerji dağılımı Puhan ve ark. iris alanını bulmak için kullanmışlardır (Puhan ve ark., 2011). Fourier gibi bir diğer frekans alanında çalışmada da Bendale ve ark., Hough dönüşümünün gelişmiş bir halini irisin merkezini ve yarıçapını bulmak için kullanmışlardır (Bendale ve ark., 2012). Hough dönüşümünün farklı halleri ise daha sonra Farihan ve ark., tarafından kullanılmıştır (Mat Raffei ve ark., 2013).

İris tanımdaki en büyük zorluklardan biri invazif olmayan şekilde en yüksek çözünürlükte iris görüntülerini alabilmektir. Hâlihazırda üç farklı tipte kamera sistemi bu işlem için kullanılmaktadır. Bu tipler NIR (Near infrared - Yakın kızılötesi), yüksek çözünürlüklü renkli kameralar ve teleskop tipli iris kameralardır. NIR kameralar bu bunlar içinde en çok kullanılan kamera ailesini oluşturmaktadır. Ancak NIR aydınlatmadan kaynaklanan sorunlar ortaya çıkabilmektedir. Koh ve ark., gözbebeğinin merkezini histogram ile bulup, oluşan hataları aktif kontur modelleri ile düzelttikleri çalışmada, NIR aydınlatmadan kaynaklanan homojen olmayan yoğunluk metodun önemli dezavantajlarından biridir. Bununla birlikte metot yüksek hesaplama maliyeti gerektirmektedir (Koh ve ark., 2010). Kameralar üzerindeki çalışmalarda, Benalcazar ve ark. görünür ışık ve near infrared imaging sistemlerin (yakın kızılötesi görüntüleme-NIR) iris resimlerinin tanımlanması üzerindeki etkilerini incelemişlerdir (Benalcazar ve ark., 2019).

Restorasyon (Inpainting), görüntü boyama, eski ve bozulmuş görüntüleri onarma sanatı yıllardır kullanılmasına rağmen, görüntü işleme tekniklerindeki son gelişmeler nedeniyle daha da popülerlik kazanmıştır. Görüntü işleme araçlarının iyileştirilmesi ve dijital görüntü düzenleme esnekliği ile otomatik görüntü boyama, bilgisayarlı görmede önemli uygulamalar bulmuş ve görüntü işlemede önemli ve zorlu bir araştırma konusu haline gelmiştir (Elharrouss ve ark., 2016). Bu çalışma ilk olarak Bertalmio ve ark. tarafından ortaya atılmıştır (Bertalmio ve ark., 2000).

Gerçek zamanlı uygulamalarda, kameraların görüş açılarının küçük olması sebebi ile görüntü üzerinde bulanıklaşma olabilmektedir. Kang ve Park; bu odak problemi için çekirdek (kernel) tabanlı bir çözüm önermişlerdir. Sınırlandırılmış en

küçük kareler restorasyon filtresi ile tanımlanan bu metot, görüntüyü netleştirmiş ve odağı düzeltmiştir (Kang ve Park, 2007).

İris görüntü edinimi için kullanılan sistemde iristeki zengin detayların yakalanması için, yakalanan görüntüdeki iris çapı en az 50 piksel olmalıdır (Yingzi, 2006). Bazı iris kameraları (Örneğin OKI IRISPASS-WG, Panasonic BM-ET 500 ve BM-ET 300) iki irisin birden görüntüsünü alabilirken, yüksek çözünürlüğe sahip renkli iris kameraları da iris tanıma alanında kullanılmaktadır (Yingzi, 2006). Ayrıca Matey Group'un geliştirdiği "İris on the move" (hareketli iris yakalama) isimli kamera 3 metreye kadar iris algılama yapabilmektedir (Yingzi, 2006).

Lim ve ark. bir CCD kamera yardımıyla uzak mesafeden göz görüntüleri elde etmiş ve aydınlatma nedeniyle ortaya çıkan yansıma etkisini en aza indirmek için, çevreleyen ışıklar için iki halojen lamba düzenlenmiştir (Lim ve ark., 2001).

İris tanıma sistemleri Hindistan'da devlet kurumları tarafından geliştirilmiştir ve sahada kullanılmaktadır. Hindistan iris tanıma kodunu kimlik numarası olarak kullanan ilk ve en büyük ülke olma konumundadır. Benzer olarak Hollanda, Birleşik Arap Emirlikleri, Birleşik Krallık, Amerika Birleşik Devletleri ve Kanada'da iris tanıma sistemleri halk seviyesinde kullanılmıştır (Daugman, 2005).

İris tanıma için özellik çıkarma algoritmalarıyla da farklı çalışmalar yapılmıştır. Bae ve ark. tarafından Bağımsız Bileşen Analizi (BBA) (ICA-Independent Component Analysis) iris görüntüsünden özelliklerin çıkarılması için kullanılmıştır. Normalize edilmiş iris görüntüsünün 1B imzası Gauss fonksiyonu ile hesaplanmıştır. Daha sonra bu imzaya çok bazlı fonksiyonun ağırlıklandırılmış lineer kombinasyonu ile yaklaşım yapılmıştır. Son olarak ağırlıkların polaritesine göre iris kodu oluşturulmuştur (Bae ve ark., 2003). 2005'te daha sonra TBA (Temel Bileşen Analizi) (PCA-Principle Component Analysis) ve global ICA görüntü kodlama tekniğini kullanarak açılı iris görüntülerini işlemek için bir algoritma geliştirilmiştir (Dorairaj ve ark., 2005). 2005'teki bir diğer çalışmada ise 2B ağırlıklandırılmış TBA ile elde edilen özellikler ICA ile analiz edilmiştir (Wang ve Han, 2005).

Son yıllarda iris tanıma sistemlerinde makine öğrenmesi algoritmaları da kullanılmıştır. 2010 yılında, irisin arkaplandan ayrılması için YSA tabanlı gözetimli bir makine öğrenmesi metodu önerilmiştir. Sinir ağı, her bir piksel için hesaplanmış özellik kümeleri ile eğitilmiştir. Polinom uyumlaştırma (fitting) ise iris sınırlarının parametrize edilmesi için kullanılmıştır. Bu metodun dezavantajı, özellik kümelerinin hesaplanması için yapılması gereken hesaplama fazlalığıdır (Proença, 2010).

Sadece iris tanıma alanında kullanılmayan iris kodları, aynı zamanda kriptoloji alanında gizli anahtar olarak da kullanabilmektedir. Ziauddin ve Dailey iris kodunu baz alan bir biometrik gizli anahtar oluşturmuşlar, sistemin geleneksel kriptolojik metodlarla oluşturulmuş gizli anahtarlardan daha yüksek güvenliğe sahip olduğunu göstermişlerdir (Ziauddin ve Dailey, 2010).

Wang ve ark. Adaboost ve çoklu oryantasyonlu 2B Gabor filtreleri kullanarak gürültülü iris görüntüleri için bir tanıma sistemi tasarlamışlardır. Bu yöntemde iris dış sınırı, ikili bir segmentasyon maskesi kullanılarak lokalize edilmektedir (Wang ve ark., 2012). 2014'te Mahalanobis uzaklığı ile eğitilen makine öğrenmesi metodu kullanılırken (Liu ve ark., 2014), 2016'daki segmentasyon aşamasında konvolüsyonel sinir ağının kullanılmasının, sonuçlara olumlu yönde etki yaptığı vurgulanmıştır. Metot, herhangi bir ön işleme veya son işleme uygulamadan, kullanıcı gözetimli bir özellik seti oluşturmadan kullanılabilir. Konvolüsyon işleminin yavaş olması bu metodun dezavantajlarından biri olsa da, paralel programlama ile bu yavaşlık nispeten aşılabilmektedir (Liu ve ark., 2016).

Minaee ve ark., VGG-net kullanarak iristen özellik çıkarmışlardır. Dizi halinde uygulanan konvolüsyon katmanları ile derin özelliklere ulaşılmıştır. Boyut azaltma (dimensionality reduction) ise TBA ile yapılmıştır. Metodun dezavantajı yüksek hesaplama zamanı gereksinimidir (Minaee ve ark., 2016). İris tanıma sistemlerinin çözüm getirdiği problemler çeşitlenmektedir. Mülteci kampındaki bir kadının kimliğinin belirlenmesi problemi Daugman'ın iris tanıma sistemi ile çözülmüştür. Çeşitli ülkeler tarafından çocuk kaçakçılığında kaybolan çocukların izlerinin bulunması amacı ile de iris tanıma kullanılmıştır (Aloudat ve ark., 2016).

Nguyen ve ark., derin özellikleri çıkarmak için ESS (Evrişimsel Sinir Ağları) (CNN-Convolution Neural Network) kullanmışlardır. Değişik tipteki katmanlar kaba ve ince (coarse and fine) özellikleri elde etmek için kullanılmıştır. Daha önceki çalışmalara göre daha az katman ile daha fazla parametre elde edilmiş ve tanılama performansı artırılmıştır (Nguyen ve ark., 2018).

Son yıllarda farklı alanlarda kullanılan sezgisel algoritmalar iris tanıma uygulamalarında da kullanılmıştır. Parçacık Sürü Optimizasyonu (PSO) (Particle Swarm Optimization) gibi sürü zekası teknikleri çok boyutlu uzaydan optimal özelliklerin seçimi noktasında daha az hafıza ve hesaplama karmaşıklığı gerektirmektedir.

Roy ve Bhattacharya, tarafından çok amaçlı Genetik Algoritma (GA) temelli hibrit özellik seçimi yöntemi incelenmiştir. Amaç fonksiyonunu en iyi sağlayan özellik alt kümesi seçilerek tanılama başarısı artırılmıştır. Birinci aşama olarak 1B Gabor dalgacığı özellikleri hesaplanmıştır. Dalgacık özellik setinin boyutunun azaltılması ve hata oranı düşürülmesi için GA ve pareto optimizasyonu kullanılmıştır. Bu metodun dezavantajı yüksek hesaplama karmaşıklığıdır (Roy ve Bhattacharya, 2008). 2011’de yapılan bir çalışmada iris tanıma sisteminin performansını artırmak için 4 kriterli GA-tabanlı özellik seçimi incelenmiştir. 2048 boyutlu bir özellik vektörü, önerilen metot ile 105 boyutlu bir özellik vektörüne düşürülmüştür. Düşürülen özellik vektörü boyu başarıyı olumsuz yönde etkilememiştir (Roy ve ark., 2011). 2014’teki çalışmada iris-yüz multi-model tanılama sistemi çalışmalarında, global ve lokal tanımlayıcılar birleştirilerek büyük bir veri seti oluşturulmuş ve en nitelikli özellik PSO-tabanlı zeka tekniği ile seçilmiştir (Eskandari ve ark., 2014). Daha sonraları 2016 ve 2018’te de PSO ile farklı çalışmalar yapılmıştır (Hashim ve ark., 2016; Subban ve ark., 2018).

Sözlük öğrenmesi, farklı modelleri ve çeşitleri ile birlikte; ses işleme ve sınıflandırma (Adler ve ark., 2012; Zubair ve ark., 2013), veri görselleştirmesi (Mailhe ve ark., 2009; Caballero ve ark., 2014), duygu ve hareket tanıma (Wang ve ark., 2012; Zheng ve ark., 2012; Liu, ve ark., 2012), yüz tanıma (Yang ve ark., 2010; Lu ve ark., 2014), resim sıkıştırma (Nejati ve ark., 2016; Wang ve ark., 2017), gürültü giderme (Li ve ark., 2012; Yan ve ark., 2013), yeniden boyama (impainting) (Adler ve ark., 2012; Li ve ark., 2014), görüntü süper çözünürlüğü (Yang ve ark., 2011; Junjun ve ark., 2014), medikal görüntüleme (Leeve ark., 2010; Deshpande ve ark., 2015), hareket ve veri segmentasyonu (Jain ve ark., 2012), sinyal sınıflandırma (Gangeh, 2013; Gr ve ark., 2017), görüntü sınıflandırma (Deshpande ve ark., 2015; Bahrapour ve ark., 2016), ses sınıflandırma (Henaff ve ark., 2011; Yeh ve ark., 2012) ve desen analizi (Pham ve ark., 2008; Gu ve ark., 2014) gibi alanlarda geniş olarak kullanılmaktadır (Gangeh ve ark., 2015).

Sözlük öğrenmesinin K-Tekil Değer Ayrışımı (K-TDA) (K-SVD – K-Singular Value Decomposition) (Aharon ve ark. 2006), Denetimli Sözlük Öğrenme (Mairal ve ark., 2008), Çevrimiçi (Online) Sözlük Öğrenme (Mairal ve ark., 2009b), Discriminative sözlük öğrenme (Zhang ve ark., 2010), Parametrik olmayan Bayes Sözlük öğrenmesi (M. Zhou ve ark., 2009), Çoklu-Seviye Discriminative Sözlük Öğrenme (Shen ve ark., 2013) gibi istatistik temelli ve ayrıca yapay sinir ağları temelli

(Lin ve ark., 2018) tipleri bulunabilir. Sözlük öğrenmenin denetimli (Wang ve ark., 2012) ve denetimsiz (Zhong ve ark., 2018) çeşitleri de bulunmaktadır.

Bu çalışmada K-TDA ile görüntü ayırt edici özelliklerinin vurgulanması ile iris tanıma yapılan bir sistem önerilmiş ve sonuçlar literatür ile karşılaştırılmıştır. Sözlük öğrenmesinin iris tanıma alanında nasıl kullanılacağına dair bir çalışma ortaya konulmuştur.



3. MATERYAL VE YÖNTEM

3.1 Biyometrik Sistemler

Bir insanı herhangi bir uygulama veya izin için doğrulamanın üç farklı geleneksel metodu vardır. Bunlar bir kişinin sahip olduğu eşyalar (Kartlar, pasaportlar, anahtarlar vb.), sahip olduğu bilgiler (pin, şifreler vb.) ve biyometrik tanımlayıcılarıdır. Bu üç geleneksel metot bazen birleştirilerek de kullanılabilir (Majekodunmi ve Idachaba, 2011).

Biyometri kelimesi, Yunanca “bios” (yaşam) ve “metrikos” (ölçü) kelimesinden gelmektedir. Biyolojik özelliklerin istatistiksel analizini içeren bir bilimi ifade eder. Biyometrik tanıma ise, sahip olduğunuz bir nesneye (anahtar, kart vb.) veya bildiğiniz bir bilgiye (şifre, PIN vb.) bağlı olan klasik yöntemler yerine, kişiye özel biyolojik özellikleri kullanan güvenlik uygulamalarını ifade etmektedir. Biyometrik özelliklerin güzel bir özelliği, herhangi bir şeyi taşımanıza veya şifre hatırlamanıza gerek bırakmamasıdır (Faundez-Zanuy, 2006).

“Biyometrik Sistemler”, kişilerin kendilerine has fizyolojik özelliklerini ölçen ve bu özellikleri kullanarak teşhis ve doğrulama uygulamalarında kullanılan genel bir tekniktir (Jain ve ark., 2006). Biyometrik sistemler çok sayıda uygulamada kullanılabilir. Güvenlik ve doğrulama işlemlerinde fizyolojik ve davranışsal özelliklere dayanan ve değiştirilemeyen özellikler üzerine bina edilen biyometrik sistemler daha fazla güvenlik ve pratiklik vaat etmektedir. Klasik yöntemler ya da biyometrik sistemlerin kullanılmasındaki avantaj ve dezavantajlar Çizelge 3.1’de gösterilmektedir.

Biyometrik sistemlerde farklı karakteristik özellikler kullanılabilir. İyi bir biyometrik özellik, evrensellik, ayırt edicilik, kalıcılık, toplanabilirlik, kabul edilebilirlik, performans ve güvenlik olarak bir dizi özelliği gerçekleştirmelidir (Faundez-Zanuy, 2006). Biyometrik özelliklerin her biri istenilen faktörlerin tamamını sağlamasa da belli başlı özellikleri onların doğrulama sistemi olarak kullanılmasını sağlamaktadır.

Çizelge 3.1. Doğrulama yöntemlerinin karşılaştırılmaları (Faundez-Zanuy, 2006)

Doğrulama Yöntemi	Avantajları	Dezavantajları
Nesne tabanlı (kart, kimlik, pasaport, vb.)	- Yeni bir tane çıkarılabilir. - Farklı bir ülkede, tesiste vb. kullanılabilir	- Çalınabilir. - Sahtesi yapılabilir. - Paylaşılabilir. - Bir kişi farklı kimliklerle kayıt edilebilir.
Bilgi tabanlı (şifre, PIN vb.)	- Basit ve ekonomik bir yöntemdir. - Sorun varsa kolayca yenisiyle değiştirilebilir.	- Tahmin edilebilir veya bilgisi çalınabilir. - Hatırlamak bazen zordur. - Paylaşılabilir. - Bir kişi farklı kimliklerle kayıt edilebilir.
Biyometrik (parmak izi, iris, el izi vb.)	- Kaybedilmez, unutulmaz, tahmin edilemez, çalınmaz, paylaşılamaz vb. - Bir kişinin birkaç kimliği olup olmadığını kontrol etmek oldukça kolaydır. - Diğerlerinden daha fazla güvenlik sağlayabilir.	- Bazı durumlarda sahte bir tane çıkarılabilir. - Değiştirilemez ya da gizli değildir. - Bir kişinin biyometrik verileri çalınırsa, değiştirilmesi mümkün değildir.

Biyometri uygulamalarının amacı, kişilerin kimlik tespiti için yanlarında herhangi bir şey taşımak (kimlik kartı, tanıtım cihazı vb.) ya da bilgiyi hatırlamak yerine (şifre, parola vb); kişinin kopyalanması ya da taklit edilmesi imkânsız olan kendine ait parmak izi, retina, iris veya ses gibi biyolojik özelliklerini kullanmalarını sağlamaktır. Çizelge 3.2’de farklı biyometrik sistemlerin çeşidine göre hangi özelliğin kullanıldığı kısaca gösterilmiştir.


Çizelge 3.2. Biyometrik Karakteristiklerin Özellikleri

Biyometrik Karakteristik	Kullanılan Özellikler
Parmak İzi	Parmak satırları, gözenek yapısı
İmza Tanıma	Basınç ve hız ile yazma farkları
Yüz	Göz, burun vb. arası uzaklıklar
İris	İris Deseni
Retina	Retina yapısı
El Geometrisi	Parmak ve avuç içi ölçüleri
Damar	Elin arkası, parmak veya avuç içi damar yapısı
Ses	Ton ya da ses rengi
Koku	Kokunun kimyasal bileşimi
Klavye Vuruş	Klavye vuruşlarının ritmi

En çok kullanılan biyometrik sistemler; parmak izi tanıma, ses tanıma, yüz tanıma ve iris tanımadır.

3.1.1. Parmak İzi Tanıma

Parmak izi tanıma veya parmak izi doğrulaması, kişinin aynı parmağından alınan iki ayrı parmak izi arasındaki eşleşmeyi doğrulamanın otomatik yöntemini ifade etmektedir. Parmak izi elektronik olarak taranır ve buna göre bir referans şablonu oluşturulur. Parmak izleri kişiye özgüdür. Adli topluluk içinde, farklı insanların aynı parmak izi detaylarına sahip olmadığına inanılmaktadır. Hatta ikizlerin bile farklı parmak izleri olduğu gösterilmiştir (Pankanti ve ark., 2002). Parmak izlerinin benzersizliği, kolluk tanımlama uygulamalarında yaygın olarak kullanılmasının önünü açmıştır. Ayrıca erişim kontrolü, zaman, katılım takibi ve bilgisayarla kullanıcı girişi gibi sivil uygulamalarda kullanımını da mümkün olmuştur. Kişi tanımlama için parmak izi, diğer parmak biyometriklerine göre avantaj sağlamıştır. Çünkü parmak izi edinmenin yüzyıllardır kâğıt üzerine mürekkepli parmaklar ve kil gibi malzemelerdeki doğrudan izlenimler şeklinde olması mümkün olmuştur. Mürekkep kullanılmadan parmak izleri elde etmek için son on yılda birçok yeni teknik geliştirilmiştir. Mürekkepsiz yöntemlerin temel prensibi, tarayıcının yüzeyi ile temas halinde olan parmak üzerindeki çıkıntıları algılamaktır. Alınan görüntüye “canlı tarama” denir ve tarayıcılara “canlı tarama” parmak izi tarayıcıları denir (Ashbourn, 2015). Parmak izi tanıma için kullanılan örnek parmak izleri Şekil 3.1’de verilmiştir.



Şekil 3.1. Çeşitli Parmak İzi Örnekleri (Sayeed ve ark., 2016)

Parmakizi tanımanın avantajlarını şu şekilde sıralayabiliriz:

- 1) Adli soruşturmada parmak izi kullanışlıdır.
- 2) Düşük teknoloji araçları kullanarak numune toplama kolaylığı bulunmaktadır.
- 3) Farklı firmaların, büyük kapasitede parmak izi veritabanları vardır.

Parmakizi tanıma olası problemler ve dezavantajlar ise şunlardır:

1) Parmak izinin kalitesinin popülasyona göre değişimi olabilmektedir. Bir kişinin parmak izi görüntüsü yaşa, elindeki yağ oranına (kuruluk veya ıslaklık), kesilmiş veya yıpranmış parmaklara, yani genel olarak mesleğe ve yaşam tarzına bağlı olabilmektedir.


2) Dokunma-algılama yöntemleri, sensörün temizliği, hijyeni ile ilgili potansiyel sorunlar nedeniyle parmak derisindeki elastik bozulmalara karşı hassas olabilmektedir.

3) Bazı çok nadir durumlarda, parmaksız veya tam parmak sahibi olmayan kişiler, sistemin çalışma verisi bakımından sorun olabilmektedir (Yager ve Amin, 2004).

3.1.2. Ses Tanıma

Ses tanıma ise, kimliği doğrulamak için konuşma dalgalarında bulunan konuşmacıya özgü bilgileri kullanarak bireyi konuşması yoluyla otomatik olarak tanıma işlemidir.

Ses tanıma sistemi ile ilgili ilk çalışmalar 1952 yılında Bell Laboratuvarı'nda yapılmıştır. Audrey adı verilen bu sistem, sadece bir kişinin sesinden kaydedilen [0, 9] arası tamsayıların seslendirmelerini tanıma özelliğine sahipti. Daha sonra Amerika Birleşik Devletleri Savunma Bakanlığı ve farklı kuruluşlar konuşma tanıma sistemleri üzerinde çalışmış ve yeni sistemler geliştirmişlerdir. Ses tanıma için temel olarak, belli bir zamanda içinde sesin frekans bilgisi elde edilerek, kişiye ait özellikler çıkarılmaktadır (Şekil 3.2). 2010 yılında Google sesli aramayı ve daha sonra 2012'de Apple, insanların mobil cihazlarda birçok özelliği sesli komutlarla kullanabileceği Siri'yi geliştirmişti. Ses tanıma uygulamaları günümüzde daha popüler hale gelmektedir ve uygulama sayısı her geçen gün artmaktadır (X. Huang ve ark., 2014).



Şekil 3.2. Ses Spektrogramı (Dumpala ve Alluri, 2017).

Hem akustik modelleme hem de dil modelleme, modern istatistiksel tabanlı konuşma tanıma algoritmalarının önemli parçalarıdır. Gizli Markov Modelleri (HMM- Hidden Markov Model) birçok sistemde yaygın olarak kullanılmaktadır. Dil modelleme, belge sınıflandırma veya istatistiksel makine çevirisi gibi diğer birçok doğal dil işleme uygulamasında da ses tanıma kullanılmaktadır.

Konuşma tanıma sistemlerinin performansı genellikle doğruluk ve hız açısından değerlendirilmektedir. Doğruluk genellikle kelime hata oranı (Word Error Rate - WER) ile derecelendirilirken; hız, zaman ile ölçülür. Diğer doğruluk ölçüleri arasında Tek Kelime Hata Oranı (Single Word Error Rate - SWER) ve Komut Başarı Oranı (Command Success Rate -CSR) bulunmaktadır.

Bilgisayarlı sistemlerde konuşma tanıma oldukça karmaşık bir sorundur. Seslendirmeler aksan, telaffuz, artikülasyon, pürüzlülük, genizlik, perde, hacim ve hız açısından farklılık göstermektedir. Ayrıca konuşma, arka plan gürültüsü ve ekolar, elektriksel özellikler tarafından bozulabilmektedir.

Ses tanıma sistemlerinde ilk adım, dil verisini barındıran ses sinyalinin bileşenlerinin belirlenmesidir ve bu sinyallerin gürültüden arındırılmasıdır. Ses sinyalinin yüksek frekanslı bileşenleri, düşük frekanslı bileşenlerden daha önemlidir. Ses genellikle arkaplan gürültüsü ile kayıt altına alınır. Bundan dolayı Sinyal Gürültü Oranı (SNR – Signal to Noise Ratio) iyileştirir (Seshadri ve Penchalaiah, 2011). Bunun için esas ses verisi, sistem arka plan seslerinden ve düşük frekanslı bileşenlerden

ayrılarak, daha iyi ve net bir şekilde elde edilmeye çalışılır. Sonraki aşamada insan sesinin özellik matrisi çıkarılır. Özellik matrisi bir sesin karakteristiğini içerir. Bunun için ses sinyalleri birbiri ile örtüşen küçük çerçevelere (frame) bölünür. İşlemler bu çerçeveler üzerinden yapılır (Rashid ve ark., 2008; Ernawan ve ark., 2011). İyi performansından dolayı çoğunlukla ses tanıma sistemlerinde 1980'lerde Davis ve Mermelstein tarafından geliştirilen MFCC algoritması kullanılmaktadır (Davis ve Mermelstein, 1980).

3.1.3. Yüz Tanıma

Yüz tanıma, bir kişiyi dijital bir görüntüden, video kaynağından (bir video karesinden) otomatik olarak tanımlama veya doğrulama işlemidir. Bir şablon elde etmek için yüzün bir görüntüsü yakalanır ve analiz edilir. Bu analiz, sınırların belirlenmesi için geometrik noktaların çizilmesinden piksellerin gri tonlu analizine kadar çeşitli biçimlerde olabilir (Ashbourn, 2015). Yüz tanıma algoritmaları iki ana yaklaşıma ayrılabilir:

1. Ayırt edici özelliklere bakan geometrik yaklaşım.
2. Bir görüntüyü değerlere ayıran ve varyansları ortadan kaldırmak için değerleri şablonlarla karşılaştıran istatistiksel bir yaklaşım olan fotometrik yaklaşım.

Genel olarak, yüz tanıma sistemleri, ilk olarak sahnedeki yüzü algılayarak ilerler. Daha sonra çevirme, ölçek ve düzlem içi dönüşleri hesaba katarak görüntüyü normalize eder. Görüntülerde ve videolarda yüz bulmaya yönelik birçok yaklaşım geliştirilmiştir.

Yüz tanıma sistemlerinin öne çıkan avantajları aşağıdaki gibi sıralanabilir:

1. Yüz tanıma sistemleri biyometrik örnekleme açısından temas gerektirmediğinden daha kolaydır.
2. Yüz tanıma sistemleri eski fotoğraf veritabanları, videokaset ve diğer görüntü kaynakları ile çalışabilir.
3. Küçük ölçekli doğrulama uygulaması için oldukça iyi bir biyometrik tanımlayıcıdır.

Yüz tanıma sistemleri için bazı dezavantajlar şunlardır:

1. Otomatik yüz tanıma sistemlerinde, yüzün kontrollü ışık kaynakları tarafından iyi aydınlatılması gerekir.

2. Yüz tanıma, tanımlama (identification) için zayıf bir biyometriktir, ama doğrulamada (verification) daha iyi performans gösterir.

3. Yüz tanıma sistemlerinin, farklı yüz şekilleri ile yanıtılması kolay olmaktadır (Kaur ve ark., 2020).

Yapılan bu tez çalışması, biyometrik sistemlerin bir alt dalı olan iris tanıma üzerine gerçekleştirilmiştir.

3.2. İris Tanıma Sistemleri

İris terimi, yunan terminolojisindeki “ipis” kelimesinden gelmektedir. Anlam olarak gökkuşağı manasına gelmektedir. Anatomik olarak irisin oluşumu, gebeliğinden üçüncü ayından itibaren başlayıp, kişinin sekiz aylık olma sürecine kadar devam etmekte ve bu aylarda çoğunlukla tamamlanmış olmaktadır. İris oldukça korunaklı bir iç organdır (gözkapakları, kirpikler ve kornea tarafından) ve belli bir uzaklıktan görünebilir. Yüksek kompleksliğe sahip rastgele desenlerden oldukça fazla sayıda içerir ve kararlı bir yapıdadır (epigenetik olarak desenler biriciktir). İrisin desenlerinin diğer tüm biyometrik tanımlayıcılardan daha fazla ayırt edilebilir olduğu gösterilmiştir (Bowyer ve ark., 2008).


İris tanıma, invazif (kesi veya doku alınmasını gerektirmeyen) olmayan doğrulama çalışan bir sistemdir. İnsan irisinde belirgin olan uzamsal modeller bireye özgüdür. Yüz gibi, iris uzaktan (yani, invaziv olmayan) değerlendirme için kullanılabilen açık bir organdır. Bununla birlikte, insan yüzünün aksine, herhangi bir irisin görünümündeki değişkenlik, hâlihazırda mevcut bilgisayarla görme teknolojilerine dayanan otomatik bir tanıma sistemini mümkün kılacak kadar öznelliğe sahiptir (Wildes, 1997; Daugman, 2004). Ayrıca iris, gözbebeği boyut değiştirdiğinde de elastik olmayan şekilde değişmektedir.

İrisin aşağıdaki özellikleri onu bir biyometrik tanımlayıcı olarak öne çıkarmaktadır:

1. Yaygınlık: Her insan irisi, kişinin kendine özgü desensel özelliklere sahiptir.
2. Biriciklik: İris desenleri kişiden kişiye farklılık göstermektedir ve bu değişkenlik ölçülebilir derecede yüksektir.
3. Ayrışabilirlik: İris desenleri yüksek rastgeleliktedir ve çok yüksek boyutsallığa sahiptir.
4. Kalıcılık: İris desenleri kişinin hayatı boyunca sabit kalır.

5. Ölçülebilirlik: İris deseni farklı metotlarla ölçülebilir ve elde edilebilirdir.
6. Performans: Kararlı, hızlı ve isabetli sistemler oluşturmaya elverişlidir.
7. Uygunluk: Kişilerin irisi biyometrik tanımlayıcı olarak kabul etme oranları kabul edilebilirdir. (Winston ve Hemanth, 2019)

İris tanıma, bir bireyin gözlerinin desenlerinin yüksek çözünürlüklü görüntülerine dayanan tanıma tekniklerini kullanan bir biyometrik kimlik doğrulama yöntemidir. Bu yöntemde iris, gözün göz bebeği ve sklera (göz bebeğinin etrafında bulunan beyaz renkli sert tabaka) kısımlarından ayrılarak, kızılötesi veya renkli bir görüntüleme işlemiyle yakalanır (Şekil 3.3). Daha sonra irisin trabekül örgüsü içindeki detay analizinden bir şablon elde edilir (Daugman, 2004; Ng ve ark., 2008).



Şekil 3.3. Gözün bölümleri

İris tanıma teknolojisi, irisin detay açısından zengin, karmaşık yapılarının görüntülerini oluşturmak için dışbükey korneadan gelen aynı yansımayı azaltan yakın kızılötesi aydınlatmaya sahip kamera teknolojisini kullanır. Bu görüntüler, bir bireyin açık bir şekilde pozitif tanımlanmasını sağlayan irisin matematiksel temsillerini sağlamak için dijital şablonlara dönüştürülür.

Bir iris tanıma algoritması ilk olarak bir göz fotoğrafında irisin ve gözbebeğinin yaklaşık eşmerkezli dairesel dış sınırlarını tanımlamak zorundadır. Daha sonra yalnızca irisi kapsayan piksel kümesi, iki iris görüntüsü arasında istatistiksel olarak anlamlı bir karşılaştırma için gerekli olan bilgiyi koruyan bir bit desenine dönüştürülür. Kullanılan matematiksel yöntemler, fotografik görüntüler için modern kayıplı sıkıştırma algoritmalarına benzemektedir.

İris tanıma sistemleri, tanılama ve doğrulama yapan sistemlerdir. Bunun için çeşitli önışlem teknikleri (Gauss bulanıklaştırması, kenar bulma teknikleri vb.) ile irisin lokalizasyonu yapıp, yine bilgisayarla görme algoritmaları (Gabor filtreleri, HOG

(Histogram of Oriented Gradients – Yönelendirilmiş Gradyanların Histogramı özellikleri vb.) ile resim üzerindeki öznitelikler çıkarılmaktadır. Son aşamada ise çeşitli makine öğrenmesi ve karşılaştırma yöntemleri kullanılarak (Yapay sinir ağları, Hamming uzaklığı vb.) doğrulama ve tanılama yapılmaktadır (Daugman, 2004).

İris tanıma sistemlerinin başarısı, birden fazla değişkene bağlıdır. Bu değişkenler kişi (subject) ve görüntüleme (imaging) olarak kabaca iki farklı kategoride toplanabilir. Bu değişkenliklerin hepsinin sistemin başarımına etkisi farklı düzeydedir (Çizelge 3.3).

Çizelge 3.3. İris Tanıma Sisteminin Başarısına Etki Eden Değişkenlikler
(Daugman, 2007; Winston ve Hemanth, 2019)

Kişi Bazlı	Görüntüleme Bazlı
Göz Rengi	İris Genişliği/Boyu
Yaş	Engeller(göz kapağı, kirpik vs.)
Göz kusurları	Görüntüleme açısı
Medikal/moda amaçlı lensler	Odak
	Işıklandırma

İris tanıma sistemlerinde tanıma işlemi, belli bir kişinin iris tanıma sistemi tarafından alınan güncel görüntü ile veritabanında bulunan kişiler arasından doğru olarak bulunması işlemidir. Doğrulama ise kişinin kimlik bilgisi içeren veri (Kimlik veya çalışan numarası, ad soyad vb.) ve sistem tarafından elde edilen güncel iris görüntüsü ile doğrulanmasıdır (Gorodnichy, 2010).

İris görüntüsünün elde edimi diğer biyometrik verilerin elde ediniminden daha zordur. İristeki zengin özelliklerin çıkarılması sistemin başarımını doğrudan etkilemekte, bu da doğru bir şekilde iris görüntüsünün alınmasını zorunlu kılmaktadır. İris görüntüsü elde etmekle alakalı problemler aşağıdaki gibi sıralanabilir:

1. Hareketli halde olan kişiden iris görüntüsü elde etme (normal yürüme, 1 m/sn)
2. Uzaktan iris görüntüsü elde etme (3-10 m arası)
3. Açılı iris görüntüleri (kameraya bakılmayan görüntüler)
4. Kontrollü olmayan ışıklandırma ortamları
5. Denetimsiz ortamlardan elde edilen görüntüler
6. Düşük çözünürlükteki görüntüler (Matey ve ark., 2006)

Cylab, Idiap Araştırma Enstitüsü, CVB Labatuvarı, Mitsubishi Araştırma Enstitüsü gibi kurumlar ve IrisTech, Eyelock, CMI Tech, IBM, LG, Iridian Technology, Siemens, British Telecom, Irisscan ve OKI gibi firmalar daha iyi bir iris tanıma sistemi geliştirmek için yazılım ve donanım geliştirmeye devam etmektedirler. Bunun yanında

Samsung, Microsoft, Fujitsu, Vivo, ZTE, Alcatel UMI ve LG gibi firmalar ise iris tanıma sistemlerini mobil cihazlarına entegre etmek ve performanslarını iyileştirmek için çalışmaktadırlar (Winston ve Hemanth, 2019).

İris tanıma sistemleri birçok farklı modülün birleşmesi ile oluştuğu için, başarınım için sadece tanılama/doğrulama başarınımları gibi performans kriterleri yeterli olmamaktadır. Bunun yanında yanlış pozitif, yanlış negatif gibi doğrulama (verification) işlemi için olan zaman bağımsız kriterler olduğu gibi, özellik çıkarma zamanı, karşılaştırma zamanı, doğrulama zamanı gibi zaman bazlı kriterler de bulunmaktadır. Ayrıca her bir modül için farklı başarı kriterleri (başarılı segmentasyon oranı, özellik çıkarma süresi, karşılaştırma zamanı vb.) de bulunabilmektedir. İris tanıma sistemlerinde tanıma ve doğrulama olarak farklı başarı kriterleri bulunmaktadır.

Tanım (identification) sistemleri için bazı kriterler şunlardır:

1. Failure to Enroll (FTE): Veritabanına kaydetmede başarısız olma oranını ifade eder. Oran başarısız olunan görüntü sayısının toplam görüntü sayısına bölünmesi ile edilir. Başarısız olunma nedenlerine örnek olarak uygun olmayan görüntü tipi, başarısız segmentasyon vb. nedenler verilebilir.

2. Failure to Acquire (FTA): Gerçek zamanlı sistemlerde sistemin kişinin irisini doğru biçimde alamadığı durumların, toplam duruma olan oranını ifade eder.

3. False Match Rate (FMR): Bir kişinin başka biriymiş gibi doğrulanma sayısının toplam doğrulama girişimi sayısına bölünmesiyle ifade edilen orandır.

4. False Non-Match Rate (FNMR): Veritabanında olan bir kişinin doğrulanmasının başarısız olma sayısının toplam doğrulama girişimi sayısına bölünmesiyle ifade edilen orandır (Gorodnichy, 2010).

Doğrulama (verification) sistemleri için ise kriterler şunlardır:

1. False Reject Rate (FRR): Veritabanında bulunan kişinin doğrulanamaması oranının toplam doğrulama sayısına oranıdır.

2. False Accept Rate (FAR): Kişinin yanlış kişi olarak sınıflandırma sayısının toplam doğrulama sayısına oranıdır.

3. Generalized False Reject Rate (GFRR): Kişinin iris resminin veritabanına kaydedilememesi ya da kaydedilmesi fakat doğrulanamaması sayısının toplam doğrulama sayısı girişimine olan oranıdır.

4. Generalized False Accept Rate (GFAR): Veritabanında olmayan kişinin resminin alınıp yanlış doğrulanması sayısının toplam doğrulama girişimine olan oranıdır.

5. Success Rate (SR): Veritabanında olan kişinin doğru sınıflandırma sayısının toplam doğrulama girişimi sayısına oranıdır.

6. Equal Error Rate (EER): Belirlenen eşik değerine göre FAR ve FRR metriklerinin eşit olduğu durumda, FAR veya FRR metriğinin değeridir (Gorodnichy, 2010).

3.3. Makine Öğrenmesi

Makine Öğrenmesi, bilgisayar bilimlerinde, yapay zekânın alt dalları olan sayısal öğrenme ve model tanıma çalışmalarından geliştirilmiş bir alt daldır. Makine öğrenmesi, öğrenebilen ve veriler üzerinden tahmin yapabilen algoritmaların çalışması ve oluşturulması süreçlerini araştıran bir sistemdir. Statik program talimatlarını harfiyen takip etmek yerine, veri setine bağlı tahminleri gerçekleştirmek ve kararları gösterebilmek amacıyla bir model oluşturulması işlemidir (Wang ve ark., 2018).

Makine öğrenmesi algoritmaları denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üç ana kategoriye ayrılmaktadır.

a) Denetimli öğrenme: Denetimli öğrenme, girdi değişkenlerinin (x) ve o girdiye ait bir çıktı değişkeninin (Y) olduğu ve girdiden çıktıya eşleme işlevini öğrenen algoritmalar. Denetimli öğrenmede, algoritmalar etiketli verilerden öğrenirler. Öğrenme işlemi bittikten sonra algoritma, desenlere dayanarak yeni verilere hangi etiketi vermesi gerektiğini belirler ve desenleri, etiketlenmemiş yeni verilere ilişkilendirir. Bayes sınıflandırıcılar, Destek Vektör Makinesi (DVM) (SVM-Support Vector Machine) algoritmaları örnek olarak verilebilir.

b) Denetimsiz Öğrenme: Denetimsiz öğrenme; etiketlenmemiş, sınıflandırılmamış veya kategorize edilmemiş verilerden öğrenen algoritmalar. Geri bildirimle cevap vermek yerine denetimsiz öğrenme, verilerdeki ortaklıkları tanımlar ve her yeni veri parçasındaki bu ortak noktaların varlığına veya yokluğuna dayanarak sonuç verir. K-Ortalama kümelemesi (K-Means), Temel Bileşen Analizi (TBA) (PCA-Principle Component Analysis) gibi algoritmalar denetimsiz öğrenmeye örnek verilebilir.

c) Pekiştirmeli Öğrenme: Bir aracının belirli eylemleri gerçekleştirerek ve bu eylemlerden elde ettiği ödülleri/sonuçları gözlemleyerek bir ortamda davranmayı öğrendiği algoritma türüdür. Pekiştirmeli öğrenme aracı temel olarak ödül maksimizasyonu hipotezi ile çalışır. Bu nedenle, ödülü en üst düzeye çıkarmak için

pekiştirmeli öğrenimin mümkün olan en iyi eylemi yapması gerekir. Pekiştirmeli öğrenmenin Q-Learning, SARSA (State-Action-Reward-State-Action), DQN (Deep Q Network), DDPG (Deep Deterministic Policy Gradient), TRPO (Trust Region Policy Optimization), PPO (Proximal Policy Optimization) gibi türleri vardır.

3.4. Sözlük Öğrenmesi

Sözlük öğrenme; makine öğrenmesinin bir alt dalıdır ve eğitim verilerinin seyrek bir sunumunu (sparse representation) “sözlük” (dictionary) adı verilen bir yapıda bulmayı amaçlamaktadır. Sözlükteki verilerin temsili ne kadar seyrek olursa, sözlüğün temsil yeteneğinin o kadar yükseldiği kabul edilmektedir (Dumitrescu ve ark., 2018).


3.4.1. Seyrek Gösterim (Sparse Coding) Kavramı

Ses sinyalleri, görüntüler, radar görüntüleri, kalp sinyalleri vb. gibi verilerde bazen çok miktarda veri olmasından dolayı, problem çözümü için gerekli bilgilerin bulunması bazen oldukça zor olmaktadır. Ele alınan veriler, belli bir zamandaki tüm değerleri içeriyorsa “sürekli veri” olarak isimlendirilirken; eğer sadece tam sayı değerleri içeriyorsa “ayrık (seyrek) veri” olarak isimlendirilmektedir. Seyrek bir gösterime sahip verilerde aranılan bilgiler az sayıda bileşen ile ortaya çıkarıldığı için, verilerin daha hızlı ve daha basit işlenmesi mümkün olabilmektedir (Rubinstein ve ark., 2010) (Şekil 3.4).

Bir giriş sinyali $x \in R^n$, $D = [d_1, d_2, d_3, \dots, d_k] \in R^{n \times k}$, normalleştirilmiş $d_j^T d_j = 1$ “temel vektörler” kümesinden oluşan bir sözlük ve $\alpha \in R_k$ olarak tanımlanabilir. Katsayı vektörü veya sinyalin temsili, “seyrek kod” olarak da bilinir. Seyrek gösterim problemi Denklem 3.1’deki gibidir.

$$\min_{\alpha} \|\alpha\|_0 \text{ s.t. } x = D\alpha \quad (3.1)$$

Burada $\|\alpha\|_0$, katsayı vektörü α ’nın l_0 normunu ve α ’daki sıfır olmayan elemanların sayısını temsil eder.



Şekil 3.4. Seyrek gösterim. (a) aşırı tam sözlük ve ayrık katsayı vektörü ile hedef sinyali yaklaşık olarak oluşturma, (b) aşırı tam sözlük ve ayrık katsayı matrisi ile hedef sinyal matrisini oluşturma (b) (Aharon ve ark., 2006)

Bir giriş sinyali x , temel vektörlerin sayısının girdinin boyutluluğundan daha büyük olduğu bir aşırı tamamlanmış (over-complete) sözlüğün atomlarının doğrusal bir kombinasyonu ile temsil edilebilir. Bununla birlikte, aşırı tamamlanmış bir temelde bir sinyal için en seyrek gösterimi bulmak çok zor bir hesaplama problemidir. Bu problem kombinatorial aramaya ihtiyaç duyar ve NP-zor problemler kategorisindedir (Fawzi ve ark., 2015; Tüysüzöğlu, 2016). Bu probleme en iyi yaklaşık çözümü bulmak için, dışbükey olmayan l_0 normu yerine, yukarıdaki soruna benzersiz bir global minimumun varlığını sağlayan dışbükey hale getirilerek l_1 normu gerçekleştirilebilir. P 'nin $[0,1]$ aralığında olduğu diğer l_p normları, daha güçlü bir seyreklilik biçimi empoze ederek de mümkündür, ancak bunlar dışbükey olmayan sorunlara yol açtığından, yaygın olarak l_1 normu kullanılır. l_p normunun genelleştirilmiş formülü Denklem 3.2'de verilmiştir.

$$\|\alpha\|_p = \left(\sum_{i=1}^k |\alpha_i|^p \right)^{1/p} \quad (3.2)$$

Burada $\alpha = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_k]$ ve önceki seyreklik formülasyonunu l_1 normuyla değiştirdikten sonra, seyrek temsil sorunu Denklem 3.3'teki gibi temsil edilebilir.

$$\min_{\alpha} \|\alpha\|_0 \text{ s.t. } x = D\alpha \quad (3.3)$$

Genel olarak, söz konusu sistem gürültüye maruz kalabilir. ϵ gürültüyü temsil etmek üzere, $D\alpha$ ve x arasında yakınlığa sahip alternatif bir çözüme ihtiyaç vardır. Bu ifade Denklem 3.4'teki gibi ifade edilebilir.

$$\alpha^* = \operatorname{argmin}_{\alpha} \|\alpha\|_1 \text{ s.t. } \|D\alpha - x\|_2 \leq \epsilon \quad (3.4)$$

Geleneksel bilgilerimize göre bir işareti (ya da sinyali) kayıpsız olarak geri oluşturabilmek için en az işaret uzunluğu kadar verimizin olması gereklidir (Denklem 3.5).

$$Ax = y, y \in \mathbb{R}^M \wedge x \in \mathbb{R}^K, M < K \quad (3.5)$$

Denklem 3.5'te, y gözlem verisini, M gözlem verisinin uzunluğunu, x gözlemlerden elde edilecek sinyali, K bu sinyalin uzunluğunu göstermek üzere $M < K$ şartı altında birden fazla çözümü bulunan düşük tanımlı bir doğrusal cebir sistemidir. Farklı şekilde ifade edilecek olursa, fazladan bilgi verilmeden y 'den x 'in elde edilmesi mümkün değildir. Seyreklik varsayımı, işaret boyutu K 'dan daha az eleman kullanarak x sinyalinin oluşturulması için yukarıda bahsedilen imkansızlık durumlarını ortadan kaldırmaya yarayan bir çözümdür (Aharon ve ark., 2006) (Denklem 3.6).

$$x \in \mathbb{R}^p \wedge d_1, d_2, \dots, d_n \in \mathbb{R}^p \quad (3.6)$$

Denklem 3.6'da x seyrek gösterimi bulunmak istenen işaret, d_i 'lerin de bu işaretin baz vektörleridir. Bu durumda sözlük (D) bu baz vektörlerden oluşur ve Denklem 3.7'deki gibi tanımlanabilir:

$$D \in \mathbb{R}^{p \times n} (p < n) \quad (3.7)$$

Bu durumda x işaretini D matrisindeki atomların (sütunların) lineer birleşimi şeklinde yazabiliriz (Denklem 3.8).

$$x = d_1 w_1, d_2 w_2, \dots, d_n w_n = \sum_{i=1}^n d_i w_i \quad (3.8)$$

Burada seyrek katsayı vektörümüz $w = [w_1, w_2, \dots, w_n]^T$ olup, $n \times 1$ boyutlarındadır. Aynı ifade Denklem 3.9'daki gibi de yazılabilir.

$$x = Dw \quad (3.9)$$

Denklem 3.9'taki D Matrisi aşırı tam bir matristir ($n \gg p$). Sütunları lineer bağımlıdır (Uzayda n adet farklı vektörün oluşturduğu matrisin determinantı sıfır ise bu vektörlerin birbirine lineer olarak bağımlı olduğu söylenebilir). x sinyalinin seyrek gösterimi için, w katsayı vektöründeki s sayıda elemanın sıfırdan farklı olması gerekmektedir. Bu $s > 0$ sayısı, l_0 normu için Denklem 3.10'daki gibi ifade edilir (Aharon ve ark., 2006).

$$s = \|w\|_0 \quad (3.10)$$

3.4.2. Seyrek Gösterimde Kullanılan Norm İfadeler

Norm, bir vektör ya da matris uzayındaki vektör(lerin) toplam boyutu ya da uzunluğudur (Dumitrescu ve Irofti, 2018).

Bir l_p normu, $x = [x_1, x_2, \dots, x_n] \in \mathbb{R}^n$ kabul edilerek, Denklem 3.11 gibi tanımlanır.

$$p \in [1, \infty) \quad \|x\|_p = \sqrt[p]{\sum_i |x_i|^p} \quad (3.11)$$

l_0, l_1, l_2 ve l_∞ gibi farklı norm çeşitleri bulunmaktadır.

l_1 Normu: Bir vektördeki elemanların mutlak değerlerinin toplamını ifade eder. Bu normda, vektörün tüm bileşenleri eşit olarak ağırlıklandırılmıştır. Denklem 3.12'deki gibi ifade edilebilir.

$$\|x\|_1 = \sum_i |x_i| \quad (3.12)$$

l_2 Normu: Öklid normu olarak da bilinen bu norm, bir noktadan diğerine gitmek için gerekli en kısa yolu ifade eder. Sinyal işleme problemlerinde ise ortalama karesel hatanın hesaplanması için de kullanılır. Diğer normlara oranla daha az seyreklik sağladığı için seyrek gösterim problemlerinde çok tercih edilmemektedir (Denklem 3.13).

$$\|x\|_2 = \sqrt{\sum_i |x_i|^2} \quad (3.13)$$

3.4.3. Farklı Norm İfadeleriyle Seyrek Gösterim Problemi

Norm ifadeleri ile seyrek gösterim yöntemleri farklılık arz etmektedir. Bu normlar seyreklik katsayı matrislerinin bulunması için kullanılırlar. Küçük bir veri kümesinde bir seyrek gösterim görevi gerçekleştirilirse, veri kümesinde gürültü ve ilgisiz özellikler dâhil olmak üzere tüm eğitim verilerini hatırladığı aşırı uydurma sorunu (overfitting) yaşanır. Bu sorun veri setinin küçük ama sınıf sayısının büyük olduğu yapay sinir ağlarında da fazlaca yaşanan problemlerden biridir. Böyle bir model, yeni testte veya daha önce görülmemiş gerçek verilerde genellikle kötü performans gösterir. Model, eğitim verilerine çok bağlı kalabilir ve bu yüzden doğru bir seyreklik çıkaramaz, gördüğü her şeyi ezberler. Bu sorunun çözümü için, “düzenleştirme” adı altında norm ifadeleri kullanılmaktadır. Seyrek gösterim probleminin çözümünde, x bileşenlerinin (ağırlıklarının) çoğunluğunun sıfır olduğu, yalnızca birkaçının sıfır olmadığı bir yaklaşıma gitmek gerekmektedir. Seyrek bir çözüm aşırı uydurmayı önleyebilir. Bu yöntemler aşağıdaki gibi sıralanabilir (Dumitrescu ve Irofti, 2018).

- l_0 norm optimizasyonu,
- l_1 norm optimizasyonu,

- $l_{2,1}$ norm optimizasyonu,
- l_2 norm optimizasyonu,
- l_p norm optimizasyonu ($0 < p < 1$)

Tez kapsamında sözlük öğrenme için l_2 norm optimizasyonu kullanılmıştır.

l_1 norm optimizasyonu ile seyrek gösterim: Seyrek gösterim problemine bir çözüm de giriş vektörüne bir l_1 normu uygulamak ve bunu mümkün olduğunca küçültmeye çalışmaktır. Küçük l_1 normuna sahip bir x , seyrek bir çözüm olma eğilimindedir.

Belirli koşullarda, l_1 probleminin çözümü, l_0 probleminin çözümü ile aynı olmaktadır. Bununla beraber l_1 normunun kullandığı kısıtlar, seyrekliği artırmaktadır. Bu iki neden ötürü, l_1 normu seyrek gösterim problemlerinde geniş bir kullanım alanı bulmuştur. l_1 normu için optimizasyon problemleri Denklem 3.14 ve Denklem 3.15'teki gibidir (Dumitrescu ve Irofti, 2018).

$$\hat{w} = \underset{w}{\operatorname{argmin}} \|w\|_1, \quad x = Dw \text{ koşulu altında} \quad (3.14)$$

$$\hat{w} = \underset{w}{\operatorname{argmin}} \|w\|_1, \quad \|x - Dw\|_2^2 \leq \varepsilon \text{ koşulu altında} \quad (3.15)$$

l_2 norm optimizasyonu ile seyrek gösterim: l_2 normu kullanılarak yapılan optimizasyon probleminde, katsayı değerleri l_1 normuna göre yüksek gelmektedir. Bunun nedeni l_2 normunun kareler toplamını temel almasıdır. Bunun dışında l_2 normu l_1 normuna göre daha kısıtlı bir seyreklik sunmaktadır. Bunun sonucu olarak daha özel çözümlerde kullanılmaktadır. l_2 normu ile seyrek gösterim Denklem 3.16'daki gibi yazılabilir (Dumitrescu ve Irofti, 2018).

$$\hat{w} = \underset{w}{\operatorname{argmin}} \|w\|_2^2, \quad \|x - Dw\|_2^2 \leq \varepsilon \text{ koşulu altında} \quad (3.16)$$

3.4.4. Seyrek Gösterimde Kullanılan Takip Algoritmaları

Seyrek gösterim optimizasyon problemi basitçe, bir x vektörünü D sözlük matrisinin bileşenleri (atomları) ile oluşturan en seyrek w ağırlık vektörünün

bulunmasını içermektedir. Seyrek Kodlama (Seyrek Gösterilim) işlemi, sözlük tasarımında gerekli bir adımdır. Bu optimizasyon problemlerinin çözümü takip algoritmaları ile gerçekleştirilir. Seyrek gösterimde kullanılan bazı takip algoritmaları aşağıda verilmiştir (Dumitrescu ve Irofti, 2018):

- Temel Takip Algoritması (Basis Pursuit - BP)
- Eşleşme Takip Algoritması (Matching Pursuit - MP)
- Dik Eşleşme Takip Algoritması (Orthogonal Matching Pursuit - OMP)
- Sıralı Özyinelemeli Eşleşme Takip Algoritması (Order Recursive Matching Pursuit - ORMP)
- Basamaklı Dik Eşleşme Takip Algoritması (Stagewise Orthogonal Matching Pursuit - StOMP)
- Sıkıştırılmış Örneklemeli Eşleşme Takip Algoritması (Compressive Sampling Matching Pursuit - CoSaMP)

Tez kapsamında Dik Eşleşme Takip Algoritması kullanılmıştır.

Temel Takip Algoritması: Bu algoritma l_1 optimizasyon problemlerinde daha çok kullanılmaktadır. Denklem 3.14 tam çözüm, Denklem 3.15 yaklaşık çözüm için kullanılabilir. Temelde lineer bir probleme indirgenebilir ve lineer programlama metodları ile çözülebilir. En büyük olasılık metodlarında (Maximum Likelihood Methods) ve diğer sözlük öğrenme metodlarında seyrek gösterim probleminin çözümü için sıklıkla kullanılan bir algoritmadır (Mairal ve ark., 2010).

Eşleşme Takip Algoritması: Bir sinyalin uyarlanabilir bir yaklaşımının sorunu için bir alt-optimal çözüm bulur. Gabor fonksiyonlarının sözlükleriyle yaygın olarak kullanılan, sinyallerin zaman frekansı analizinde, özellikle EEG / EMG sinyallerinde avantaj sağlamaktadır. Bu algoritma iteratif bir şekilde çalışır. Her adımda kullanılan aşırı tam sözlükten seyrek gösterim için bileşenlerin (atom) seçilmesi yapılır. Bu işlem durdurma kriteri sağlanana kadar devam eder. Durdurma kriterinden sonra elde edilen sinyalin seyrek gösterimi, sözlükteki bileşen sayısından daha az olur. Sonuçtaki hata, iterasyon adımlarında en çok seçilen sözlük bileşenine ortogonaldır. Bu bileşen tekrar tekrar seçilebilir. Uygulanabilirlik açısından diğer eşleşme algoritmalarına nazaran basit ve hızlıdır (Aharon ve ark., 2006).

Dik Eşleşme Takip Algoritması: Eşleşme Takip (Matching Pursuit) algoritmasının gelişmiş halidir. Algoritmalar arasında, seyrek katsayı vektörlerinin bulunması ve bu değerlerin güncellenmesi arasında farklılar bulunmaktadır.

Algoritma sözlük bileşenlerinin normalize edildiğini varsayarak işlem yapar. Her adımda farklı bir sözlük atomu seçilir. Her bir sözlük atomu seçilimi sonrası seyrek katsayı vektörü, daha önceden seçilmiş atomlar da kullanılarak en küçük kareler (Least Squares) kullanılarak hesaplanır. Hata hedefi, önceki adımlarda seçilmiş sözlük bileşenlerine ortogonaldır. Durma kriteri olarak önceden belirlenen bir adım sayısı ya da hata hedefinin belli bir değerden küçük olması kullanılabilir. Her adımda dikleştirme (ortogonalleştirme) yapıldığında, eşleşme takip algoritmasına göre daha karmaşıktır. Algoritmanın seyrek katsayı hesaplanmasında farklı metodların kullanımını öneren varyantaları da bulunmaktadır. Algoritma giriş aşamasında kullanılan aşırı tam (overcomplete) sözlüğe bağımlıdır. Yani aynı sözlük üzerinde farklı başlangıç sözlükleri farklı yaklaşımlar üretmektedir (Barthélemy ve ark., 2013).

3.4.5. Sözlük Öğrenme İle Alakalı Temel Kavramlar


3.4.5.1. Atom ve Sözlük

“Sözlük”, lineer kombinasyonla karmaşık sinyallerin oluşturulmasına izin veren ve temel bileşeni atomlar olan (bu atomlar birleşerek daha büyük bloklar oluşturabilir) bir yapıdır. Blok (yama) boyutu görüntü üzerinde hangi pencere aralıklarında gezileceğini, bunun doğal sonucu olarak da öğrenilecek atomların içeriklerini etkilemektedir. Hata hedefi (Error goal) ise K-TDA gibi algoritmalarda bulunan açgözlü

(greedy) takip algoritması yaklaşımının bir sonucu olarak optimum sonucu değil de, yaklaşık olarak ne kadar iyi sonuca ulaşacağımızı belirten bir hedeftir.

pxn boyutlu D matrisi “sözlük” olarak isimlendirilir ve bu matriste her bir sütun vektörü “sözlük atomları” (temel bileşenleri) olarak adlandırılır. Atom sayısı, sinyal uzayının boyundan daha büyük olduğu sözlüklere ($n \gg p$) “aşırı tam (overcomplete) sözlük” denir ve gereksizlik (redundancy) içerir. Bu tanımdan hareketle, seyrek gösterilim probleminde ulaşılmak istenen nokta, bir x sinyalini, w seyrek gösterim katsayı vektörleri kullanarak D sözlüğündeki atomlarla (doğrusal birleşimler kullanılarak) ifade etmektir (Dumitrescu ve Irofti, 2018). Sinyal örneklerinin sayısı arttığında kullanılan notasyon kısmen değişir ve vektörel ifadeler matrislere dönüşür.

m tane sinyali (veya örneği) içeren pxm boyutlu X matrisi $X = [x^{(1)}, x^{(2)}, \dots, x^{(m)}]$ şeklinde ifade edilir. Seyrek katsayı bileşenlerinden oluşan $n \times m$ boyutlarındaki W matrisi ise, $W = [w^{(1)}, w^{(2)}, \dots, w^{(m)}]$ şeklinde değişecek, D sözlüğü ise değişmeden kalacaktır (Şekil 3.5).



Şekil 3.5. Sözlük, seyrek katsayı vektörü ve oluşturulan x sinyali (Azizoğlu, 2017).

Bir $x \in \mathbb{R}^p$ sinyali için seyrek gösterilimle elde edilen $\tilde{x}$ sinyali Denklem 3.17 gibi hesaplanır:

$$\tilde{x} = \sum_{i=1}^n w_i d_i = Dw \quad (3.17)$$

Burada $d_1, d_2, \dots, d_n \in \mathbb{R}^p$ aşırı tam (overcomplete) sözlüğün atomları, $D \in \mathbb{R}^{p \times n}$ ($p < n$) sözlük matrisidir. w_i ($1 < i < n$ olmak üzere), i . atom için katsayı değerini göstermektedir. $\{w_i\}_{i=1}^n$ katsayıların birleşmesi ile w katsayı matrisi elde edilir. Bu matris sadece belli sayıda 0'dan farklı eleman içermektedir. Sinyali, orijinal sinyalin; sözlük ve w matrisi kullanılarak bulunmuş seyrek gösterimidir ve arasındaki fark Denklem 3.18'te verilmiştir.

$$r = x - \tilde{x} = x - Dw \quad (3.18)$$

Burada r gösterim hatası ise, x ile $\tilde{x}$ arasında farkı ifade etmekte olup, bu fark “gösterilim hatası” olarak adlandırılır.

Tek bir sinyal yerine m tane sinyalin seyrek gösterilimi için, p uzunluklu m adet sinyal içeren pxm boyutlu X matrisi $X = [x^{(1)}, x^{(2)}, \dots, x^{(m)}]$ şeklinde ifade edilebilir. m adet n uzunluklu katsayı bileşenlerinden oluşan $m \times n$ matrisi W ise, matris, $W = [w^{(1)}, w^{(2)}, \dots, w^{(m)}]$ şeklinde değişecektir. Bu bilgiler ışığında sözlük öğrenme probleminin genel ifadesi Denklem 3.19'daki gibi olacaktır (Dumitrescu ve Irofti, 2018).

$$\min_{D, W} \|X - DW\|_F^2, \forall k \ \|w^{(k)}\|_0 \leq s \text{ koşulu altında} \quad (3.19)$$

Denklem 3.19'da eğitim kümesi X (sütunlarında seyrek gösterilimi bulunmak istenen örnekler bulunmaktadır) ile W ise her bir sütunu ilgili sinyal için katsayı matrisini içeren katsayı matrisini göstermektedir. Tüm bu denklem sistemi için hesaplanacak hata R , seyrek gösterilimleri ise $\tilde{X}$ ile ifade edelim. Gösterilimler Denklem 3.20 ve toplam hata Denklem 3.21'deki gibi hesaplanabilir (Dumitrescu ve Irofti, 2018):

$$\tilde{X} = DW \quad (3.20)$$

$$R = X - \tilde{X} = X - DW \quad (3.21)$$

$\|w^{(k)}\|_0 \leq s$ ifadesi seyrekliği zorlamaktadır, W katsayı matrisi için her bir sütunda en fazla s adet sıfırdan farklı eleman olmasını garanti altına almaktadır.

$\min_{D,W} \|X - DW\|_F^2$ ifadesi ise D ve W kullanılarak hesaplanan seyrek gösterimlerdeki hataların minimum olmasını (orijinal sinyale en fazla oranda yakınsamasını) sağlamaktadır. $\|Z\|_F^2$ ifadesi ise Fobrenius formu ifade eder. Fobrenius normu $L_{p,q}$ normlarının özel bir halidir ($p = q = 2$) ve Hilbert uzayında (Vektör cebri ve hesap yöntemlerini iki boyutlu Öklid düzleminden, üç boyutlu uzayda herhangi bir sonlu veya sonsuz sayıda boyut içeren alanlara genişletilmiş uzay) tanımlıdır (Böttcher ve ark., 2008).

Sözlük öğrenme optimizasyon problemi D ve W değişken matrislerini ve bu matrislerin algoritma üzerinden optimize edilme işlemini içermektedir. Aynı anda iki değişkenin güncellenmesi zor bir problem olduğundan, uygulamalar bu iki optimizasyon işlemini ayrı ayrı adımlarda yapmaktadır. Bu adımlardan biri sözlük güncelleme, diğeri ise seyrek kodlamadır. Uygulamalar önce D sözlük matrisini sabit tutup W katsayı matrisini güncellerler; ardından W katsayı matrisini sabit tutup, D sözlüğünü güncellerler.

Seyrek kodlama aşamasında önceki bölümlerde bahsedilen takip algoritmaları kullanılmaktadır. Sözlük güncelleme aşaması ise, sözlük öğrenme algoritmasına göre farklılık göstermekte olup literatürde sözlük matrisinin hesaplanması kısmında diğerlerinden ayrılmaktadır (Aharon ve ark., 2006).

3.4.5.2. Seyreklik Faktörü

Seyrek gösterim işleminin başarısının, w katsayı vektöründeki sıfırdan farklı elemanların mümkün olduğunca az olmasına bağlı olduğuna Norm İfadeleri başlığında değinmiştik. Seyreklik derecesi ise, olan seyreklik faktörü S ile ifade edilir. Denklem 3.10'da da ifade edildiği gibi w vektöründeki sıfırdan farklı eleman sayısı s ile ifade edilir. Seyrek gösterilimi yapılmak istenen sinyaldeki eleman sayısı p olsun. Seyreklik faktörü bu durumda Denklem 3.22'deki gibi ifade edilir.

$$S = \frac{s}{p} \quad (3.22)$$


Seyrek gösterim kullanılan uygulamalar, farklı seyreklik faktörü değerlerini optimum olarak kabul ederler. Farklı S değerlerine göre seyrek gösterim kullanım alanları aşağıda belirtilmiştir (Dumitrescu ve Irofti, 2018).

- $S > 1$: Örnek sinyal boyutundan daha fazla sayıda katsayı kullanılarak sinyalin gösterilimi sağlanır. Hata esnekliğinin olmadığı ya da minimum olduğu uygulamalarda kullanılır.
- $S = 1$: Bu değeri kullanan uygulamalarda geri çatma işlemindeki hatanın minimum olması istenilir. Katsayı değerlerinin bir miktar yuvarlanması, kabul edilebilir sınırlarda bir hata oranını da beraberinde getirir. Sıkıştırma uygulamalarında kullanılır.
- $0.1 < S < 1$: Bu değer dönüşüm ya da gösterim katsayılarının eşiklenmesi ile bulunur. Gürültü azaltmada ve kayıplı sıkıştırma uygulamalarında sıklıkla kullanılır.
- $0.01 < S < 0.25$: Düşük bit hızlarında kayıplı sıkıştırma veya sinyal ya da işaretin belli özelliklerinin kullanıldığı uygulamalarda esas alınan seyreklik faktörü değeridir.
- $0.001 < S < 0.05$ aralığının kullanım alanı yukarıdaki maddelerle hemen hemen aynıdır.
- $S < 0.001$: Bu aralıktaki değerler geri dönmeyi mümkün kılmaz (Yüksek hata değerleri kullanılsa da)

3.4.5.3. Seyreklik Modeli


Bir işaret aşırı tam (overcomplete) bir sözlük ya da operatör matrisinin atomlarının doğrusal (lineer) birleşimi ile seyrek bir gösterilime sahip bir şekilde oluşturulabilir. Bu lineer oluşturma işlemi analiz veya sentez modeli ile yapılabilir.

Analiz model temel olarak sentez modele benzer. Satırları atomlardan (en küçük seyrek birimler) oluşan operatör (“analiz matris” olarak da bilinir) kullanılır ve seyrek olduğu kabul edilen bir başka dönüşüm uzayına bu analiz matrisi ile taşınır, sinyalin (ya da işaretin) seyrek gösterimi bu matris ile çarpılarak bulunur (Şekil 3.6) (Tang ve ark., 2016).



Şekil 3.6. Analiz Seyreklik Modeli (Azizoğlu, 2017).

Sentez modelde ise sözlük matrisi ve katsayı vektörlerini bulmak birincil önceliktedir. Seyrek gösterilim, bu sözlük matrisi ile katsayı vektörlerinin çarpımı ile elde edilir. İşaret az sayıda sözlük atomlarının lineer birleşimi ile oluşturulur (Şekil 3.7) (Tang ve ark., 2016).



Şekil 3.7. Sentez Seyreklik Modeli (Azizoğlu, 2017).

3.4.5.4. Sentez Seyreklik Modeli

Bu modelde işaret $y \in \mathbb{R}^M$, aşırı tam sözlük matrisi $D \in \mathbb{R}^{M \times K}$ ve mümkün olan en az sayıda sıfırdan farklı eleman içeren seyrek katsayı vektörü $x \in \mathbb{R}^K$ vardır. Önceki bölümler de değinildiği üzere sinyal $Dx = y$ şeklinde modellenir.

Aşırı tam (overcomplete) sözlüğün bileşenleri (atomları) $\{d_j\}_{j=1}^K$ ile ifade edilir. D sözlük matrisi K adet M boyutlu bileşenlerden oluşur. Seyrek katsayı vektörü x , gösterimi yapılan y işarete ait katsayıları içermektedir. Gösterimin oluşturulması esnasında x 'in sıfır olmayan elemanları kullanıldığından dolayı (sıfırdan farklı eleman sayısı en az olacak şekilde tasarlandığından dolayı) y işaretinin seyrek gösterilimi sağlanmış olur. Seyrek gösterim $y = Dx$ ($\|y - Dx\|_p \leq \varepsilon$ koşulu sağlanacak şekilde $y \approx Dx$ şeklinde yazılabilir. $\|\cdot\|_p$ notasyonu norm ifadelerini belirtmektedir.

Sentez seyreklik modelinde, seyrek katsayı vektörü ve aşırı tam sözlük matrisinin bulunması elzemdir.

Sözlük öğrenme probleminin ilk aşaması için Denklem 3.9'un çözümü yapılır. Burada amaç seyrek gösterim ile veri arasında karesel hatayı en aza indirmektir. "Seyrek kodlama problemi" adı verilen bu aşamadaki yaklaşık çözüm, önceki bölümlerde değinilen takip algoritmaları ile yapılır.

Sözlük öğrenme probleminde seyrek kodlamadan sonra sözlük güncellemesi aşaması gelir ve katsayı matrisi kullanılarak sözlük güncellenir (Yang ve ark., 2016).

3.4.5.5. Sözlük Öğrenmede Kullanılan Yöntemler

Sözlük öğrenme metodunun seyrek tabanlı çözümleri için son yıllarda pek çok farklı yöntem önerilmiştir. Kullandığı norm optimizasyonuna göre üç ana başlık altında toplanabilir (Dumitrescu ve Irofti, 2018).

- l_0 norm optimizasyonu tabanlı metodlar
- Konveks gevşeme metodları
- Konveks olmayan gevşeme metodları.

Farklı yapıların varlığına göre ise;

- İstatistik tabanlı metodlar (örn: Maksimum Olabilirlik Metodu – Maximum Likelihood Methods)

- Gruplandırma ve vektör nicemleme(quantization) tabanlı metodlar (örn K-TDA – K Tekil Değer Ayırıştırma)
- Parametrik metodlar

Sözlük öğrenme; makine öğrenmesinin denetimli veya denetimsiz de olabilen bir koludur ve eğitim (ya da giriş) verilerinin (sinyallerinin) seyrek bir sunumunu (sparse representation) ifade edecek atomları barındıran “sözlük” (dictionary) adı verilen bir yapıyı bulmayı amaçlamaktadır. Sözlükteki verilerin temsili ne kadar seyrek olursa, sözlüğün temsil yeteneğinin o kadar yükseldiği kabul edilmektedir (Dumitrescu ve Irofti, 2018).

3.4.6. Sözlük Öğrenme

Sözlük öğrenimi kavramı, sözlüğün doğrudan bir dizi mevcut veri örneğinden oluşturulmasıyla ilgilidir, böylece öğrenilen sözlük, seyrek temsil amacına iyi bir şekilde uyarlanabilir.

Gerçek sözlükler, Denklem 3.23’teki küçültme problemine bir çözüm bulunarak elde edilebilir:

$$\min_{D, \{\alpha_i\}_{i=1\dots m}} \sum_{i=1}^m \|x_i - D\alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \quad (3.23)$$

Burada $\{x_i\}_{i=1\dots m}$ ‘den her biri sınıflandırılan bir giriş sinyalini (veri örneği) temsil eder ve λ yeniden yapılandırma hatasını tanımlayan veri uydurma terimi ile seyrekliği belirleyen düzenleme terimi arasındaki ödünleşimi dengeleyen ceza parametresidir.

Denklem 3.1’deki optimizasyon problemi, D ve α değişkenleri ile ilgili olarak genellikle birlikte konveks değildir. Bir çözüm, bunlardan birini D veya α ’yı sabitlemektir, böylece diğer değişkene göre amaç işlevi dışbükey bir işleve dönüşebilir. Bu doğrultuda, optimizasyon algoritması, önceden belirlenmiş bir yakınsama kriteri karşılanana kadar yinelemeli bir yaklaşımda uygulanan iki dışbükey adımdan oluşur:

- Seyrek Yaklaşım: Sözlük D sabit kabul edilir, ardından D sözlüğüne göre sinyal $\{\alpha_i\}_{i=1\dots m}$ katsayıları Denklem 3.23’ten en aza indirilerek hesaplanır.

- Sözlük Güncelleme: Yaklaşım hatasını azaltmak için elde edilen seyrek kodlama matrisi α kullanılarak yeni sözlükler hesaplanır (Dumitrescu ve Irofti, 2018).

3.4.6.1. Gözetimli Sözlük Öğrenme

Sözlük öğrenme yöntemleri hem rekonstrüktif hem de seyrekleştirme amaçlara hizmet edecek şekilde organize edilebilir. Seyrek sözlük öğrenimi, sınıf etiketlerinin dahil edilmesiyle giriş sinyallerinin denetimli sınıflandırılması görevini ortaya çıkarır. Eğitim verilerinin etiketlerini kullanmak, sınıflandırma görevini kolaylaştırarak her sınıf için farklı veri temsilleri sağlar. Seyrek kodlama adımının amacı, yeniden yapılandırma hatası en az olan verinin en seyrek temsilini bulmaktır. Sınıflandırma için hem seyrek gösterimler hem de yeniden yapılandırma hatası dikkate alınır.

Sınıflandırma aşamasını gerçekleştirmek için, gerçek sözlük, her biri belirli bir sınıfın örneklerinin katılımıyla bağımsız olarak eğitilen alt sözlüklere ayrıştırılır. c sınıfı etiketlerinden oluşan bir eğitim verisini düşündüğümüzde, karşılık gelen sözlük tabanı $D [D_1, D_2, \dots, D_c]$ gibi n alt sözlük kullanılarak oluşturulur ve her biri aynı sayıda bir sınıfı temsil eder. Sınıf etiketi hakkında önceden hiçbir fikrimiz olmayan yeni bir test girdisinin sınıflandırılması durumunda, sinyali kodlamak için sınıfa özel alt sözlüklerin birleşimi olan gerçek sözlük kullanılır. Sinyal daha sonra en iyi yeniden yapılanmanın elde edildiği ve en seyrek çözüme götüren sınıfa atanır (Mairal ve ark., 2008; Tüysüzoğlu, 2016)

Fikri daha ayrıntılı bir şekilde ifade edersek, bir x sinyalinin sınıflandırılması için bir sözlükler koleksiyonu $[D_1, D_2, \dots, D_c]$ verilir; burada her $D_i \in R_n \times k$ aşağıdaki adımları yinelemeli olarak gerçekleştirerek yerine getirilebilir ve Şekil 3.8'de gösterilmektedir.

- Seyrek kodlama kullanarak $\alpha_1, \alpha_2, \dots, \alpha_c$ olan her sözlük D_i 'de x sinyalinin temsili hesaplanır

- Önceki adımda bulunan temsillerin maliyetini karşılaştırarak ve en düşük maliyeti sunan D_i sözlüğüne atayarak x sinyalinin sınıf üyeliğini bulunur (Denklem 3.24, Denklem 3.25)


$$\text{sınıf } i^* = \underset{i \in \{1,2,\dots,c\}}{\operatorname{argmin}} \delta_i(x) \quad (3.24)$$

$$\delta_i(x) = \min_{\alpha \in R^k} \|x - D_i \alpha\|_2^2 + \lambda \|\alpha\|_1 \text{ olmak üzere} \quad (3.25)$$

3.4.7. K-TDA Sözlük Öğrenmesi

K-TDA (K-Tekil Değer Ayrışımı) (K-SVD - K-Singular Value Decomposition) (k küme sayısını göstermek üzere) tekil bir değer ayrıştırma yaklaşımı yoluyla, seyrek temsiller (sparse representations) oluşturmak için bir sözlük öğrenme algoritmasıdır. Dar anlamda, seyrek bir veri temsili, birkaç parametrenin veya katsayının sıfır olmadığı ve çoğunun (kesinlikle) sıfır olduğu bir temsildir. Bu, sıfır olmayan bileşenlerin sayısını veren l_0 sayım indeksi ile ölçülebilir.

K-TDA, K-Ortalama kümeleme (K-Means clustering) yönteminin genelleştirilmiş bir halidir. K-ortalama kümeleme, n gözlemi, her bir gözlemin en yakın ortalama (küme merkezleri veya küme merkezi) ait olduğu ve kümenin bir prototipi olarak hizmet ettiği k kümeye bölmeyi amaçlar. Mevcut sözlüğü temel alan girdi verileri ile seyrek kodlama arasında yinelemeli olarak geçiş yaparak ve verilere daha iyi uyması için sözlükteki atomları güncelleyerek çalışır. K-TDA; görüntü işleme, ses işleme, biyoloji ve doküman analizi gibi uygulamalarda yaygın olarak kullanılmaktadır (Zhang ve ark., 2010; Rubinstein ve ark., 2012; Raja ve ark., 2016).



Şekil 3.8. İteratif Sözlük Öğrenme (Tüysüzoğlu, 2016).

K-TDA algoritmasının sözlük öğrenme alanına temel katkılarından biri, sözlük güncelleme kısmında matris tersi hesaplamak yerine, atomların (temel bileşenlerin) iteratif olarak güncellenmesini gerçekleştirmesidir. Atomlar güncellenirken, ona bağlı olarak seyrek katsayı matrisi de güncellenir, bu algoritmanın literatürden farklılaştığı bir diğer noktadır (Aharon ve ark., 2006).

TDA (Tekil Değer Ayırıştırması) (SVD-Singular Value Decomposition) bir kısım çok boyutlu veri yığınlarından az boyutlu anlamlı tekrar eden desenleri bulmak,

kimi zaman da tam aksine az boyutlu veri yığınlarından çok boyutlu anlamlar çıkarmak için kullanılan bir yöntemdir. Denklem 3.26'da formülü gösterilmiştir.

$$M = U\Sigma V^* \quad (3.26)$$

Burada; M ; $m \times n$, boyutlarında değerleri K alanından (field) gelen bir matrisi (m , en; n , boy ve K ilgili uzay); U , $m \times m$ boyutlarında elemanların K alanından gelen unitary matrisi (eşlenik matrisi ile çarpımı birim matrise eşit olan); Σ , köşegeni üzerinde negatif sayı bulunmayan $m \times n$ boyutlarında matrisi ve V^* ise $n \times n$ boyutlarında V matrisinin eşlenik transpozunu göstermektedir İşlem sonucunda Σ matrisinin diyagonal elemanları olan $\sigma_i (i = 1, 2, \dots, n)$ değerleri, M matrisinin tekil değerleri (Singular Values) olur (Biglieri ve ark., 1989). Bu tekil değerler, sözlüğün güncelleştirme aşamasında kullanılmaktadır.

K-TDA, Denklem 3.27'de verilen gibi bir K kümelemesi yapmaktadır (Şekil 3.7) (Aharon ve ark., 2006). K kümeleme, aynı zamanda seyrek bir temsil yöntemi olarak da kabul edilebilir. Yani, veri örneklerini en yakın komşunun temsil etmesi için en iyi kod çizelgesini çözerek bulmayı amaçlamaktadır.

$$\min_{D, X} \{\|Y - DX\|_F^2\} \text{ subject to } \forall i \|x_i\|_0 \quad (3.27)$$

Burada; D , seyrek atomlardan oluşan sözlük; Y , temsil edilecek sinyal vektörü; X temsil vektörü ve x_i, Y sinyalinin temsil katsayılarıdır (coefficient). F harfi Frobenius normunu belirtir. Fobrenius normu $L_{p,q}$ normlarının özel bir halidir ($p = q = 2$) ve Hilbert uzayında (Vektör cebri ve hesap yöntemlerini iki boyutlu Öklid düzleminden, üç boyutlu uzayda herhangi bir sonlu veya sonsuz sayıda boyut içeren alanlara genişletilmiş uzay) tanımlıdır (Böttcher ve ark., 2008). Seyrek gösterim terimi $x_i = e_k$, sözlük D 'de yalnızca bir atom (sütun) kullanmak için K kümeleme algoritmasının özelliklerini tek sütun (vektör) kullanacak şekilde kısıtlar. K-TDA algoritmasının işlem adımları Şekil 3.7'de verilmiştir.

K-TDA algoritmasının hedefi; sinyali, D 'deki atomların doğrusal bir kombinasyonu olarak temsil etmektir (Şekil 3.9) (Aharon ve ark., 2006).

Algoritma – 1

K-TDA Sözlük Öğrenmesi (Aharon ve ark., 2006)

Parametreler: Sözlük $D^{(0)} \in R^{n \times k}$ olacak şekilde l^2 normalize edilmiş sütunla ilklendirilir. $j = 1$ değeri verilir. Durma kuralı sağlanana kadar aşağıdaki adımlar tekrarlanır.

1: Seyrek Kodlama Aşaması: Her örnek y_i için x_i gösterim vektörleri istenilen bir takip algoritması ile aşağıdaki yaklaşım formülüne göre hesaplanır:

$$i = 1, 2, \dots, N, \quad \min_{x_i} \{ \|y_i - Dx_i\|_2^2 \}, \|x_i\|_0 \leq T_0$$

2: $D^{(j-1)}$ 'deki her bir $k = 1, 2, \dots, K$ sütunu için güncelleme işlemini aşağıdaki gibi yap:


- $\omega_k = \{i \mid 1 \leq i \leq N, x_T^k(i) \neq 0\}$ atomunu kullanan örnekler grubunu tanımla.
- Genel Gösterim Hatası Matrisi E_k 'yi aşağıdaki şekilde hesapla:

$$E_k = Y - \sum_{j \neq k} d_j x_T^j$$

- E_k 'yi sadece ω_k 'ya karşılık gelen sütunlarla kısıtla ve E_k^R 'yi elde et.
- E_k^R 'ye TDA ayrıştırması uygula $E_k^R = U\Delta V^T$. Güncellenmiş d_k sütununu U matrisinin ilk sütunu olarak seç. V nin ilk sütunu olacak katsayı vektörü x_R^k 'yi güncelle. $\Delta(1,1)$ alınarak çarpım yap.

Şekil 3.9 K-TDA İşlem Adımları

K-TDA algoritması Denklem 3.27'de verilen ifadeyi minimize etmeye çalışır. En uygun W seyrek katsayı matrisi hesaplanır, bu hesaplama yapılırken D sözlüğü sabit tutulur. Bu hesaplama esnasında daha önce de belirtildiği üzere ideal çözüme ulaşmak mümkün olmadığından yaklaşık çözüm bulmak adına çeşitli takip algoritmaları kullanılır.



Şekil 3.10 K-TDA Uygulamasına Ait Akış Şeması (D sözlük, X temsil vektörü) (Aharon ve ark., 2006).

Takip algoritmaları, W katsayı matrisindeki elemanların mümkün olan en fazla sayıda sıfır içermesini – seyrekliği – zorlarlar. (Aharon ve ark., 2006).

Eşleşme Takip (ET) algoritması her bir seferde tek bir atomu bulan açgözlü bir algoritmadır. İlk adımda giriş sinyaline en çok benzeyen atom bulunur. Daha sonraki adımlarda ise önceki atomlar da hesaba katılarak en çok benzeyen atomlar bulunmaya devam edilir (Mallat ve ark., 1993). Temel Takip (TT), bir matematiksel optimizasyon problemidir (Denklem 3.28) (Chen ve ark., 1994). Eşleşme Takip algoritmasında olduğu gibi hem de temel takip algoritmasında da işlenecek sinyale en çok benzeyen atomları bulmaya çalışır.

$$\min_x \|x\|_1, y = Ax \quad (3.28)$$

Burada; $M < N$ olmak üzere (M ve N pozitif tam sayılar); $x, N \times 1$, boyutlarında çözüm vektörü; $y, M \times 1$ boyutlarında gözlemlerin vektörü, A ise $M \times N$ boyutlarında dönüşüm matrisidir.

Seyrek kodlamadan sonraki ikinci adım ise, sözlük öğrenmesi adıımıdır. W katsayı matrisi sabit tutulurken, D sözlüğü güncellenir. Bu adımda d_i atomu hariç diğer atomlar sabit tutulur. d_i atomunun değeri güncellenirken, bu atomla ilgili diğer katsayılar da ortalama karesel hatayı (Mean Squared Error) minimize edecek şekilde aynı anda güncellenir. Diğer sözlük öğrenme metodlarında bu aşamada W katsayı matrisi sabit tutulur.

Sözlük atomlarından yalnızca birinin güncellenmesi işlemi TDA algoritması ile yapılır. Güncelleme işlemi, sözlükteki toplam atom sayısı K kadar yapıldığı için algoritma K-TDA olarak isimlendirilir. Algoritmada gerçekleştirilen atomlarla beraber katsayıların da güncellenmesi işlemi, daha sonraki atom güncellemelerini de hızlandıracağından yakınsamayı hızlandırır.

$$\|X - DW\|_F^2 = \left\| X - \sum_{j=1}^K d_j w_T^j \right\|_F^2 = \left\| \left(X - \sum_{j \neq k}^K d_j w_T^j \right) - d_k w_T^k \right\|_F^2 = \|E_k - d_k w_T^k\|_F^2 \quad (3.29)$$

Denklem 3.29'da, k . terim üzerinde işlem yapılması gösterilmektedir. $K - 1$ adet terim sabit kalmaktadır. E_k matrisi toplam hatayı göstermektedir. d_k vektörü ve w_T^k

katsayı vektörünün güncellenmiş halledir TDA ile bulunur. Bu işlem K sefer tekrarlanır. TDA, E_k matrisine yakınsayan matrisi Fobrenius Normunda bulmaktadır. Böylece hata minimuma indirilmiş olur.

Burada d_k atomunun güncellenmesi sırasında seyreklik zorlanmadığı için w_T^k rastgele olarak bulunmakta ve bu da hatalara yol açmaktadır. Bu sorun için v_k vektörünün tanımlanması önerilmiştir. Bu vektör, $\{w_i\}$ örneklerinin indislerini (d_k atomunu kullanan) barındırmaktadır. Yani w_T^k 'nin sıfırdan farklı elemanlarını içermektedir. v_k matrisi Denklem 3.30'daki gibi tanımlanmıştır.

$$v_k = \{i \mid 1 < i < K, w_T^k(i) \neq 0\} \quad (3.30)$$

Buna müteakip $N \times |v_k|$ boyutlu $(v_k(i), i)$ girişlerinde 1 değerini, diğer indislerinde ise 0 değeri bulunduran Ω_k matrisi tanımlanır. Bu matris ile w_T^k matrisinin çarpımı sonucu, w_T^k matrisinin sıfırdan farklı indislerini barındıran $|v_k|$ büyüklüğünde w_R^k vektörü bulunur (Denklem 3.31).

$$w_R^k = w_T^k \Omega_k \quad (3.31)$$

Paralel olarak, Ω_k matrisinin sinyal örneklerini içeren X matrisi ile çarpılması sonucu güncellemesi yapılan d_k bileşenini kullanan örnek sinyalleri içeren X_k^R matrisi bulunur (Denklem 3.32).

$$X_k^R = X \Omega_k \quad (3.32)$$

Aynı işlem E_k matrisi için de yapılırsa, o anda güncellenmekte olan d_k atomunu içeren sinyallere ilişkin hatayı gösteren E_k^R matrisi elde edilir (Denklem 3.33).

$$E_k^R = E_k \Omega_k \quad (3.33)$$

Bu tanımlamalardan sonra orijinal denklemdeki w_T^k ifadesini, aynı çözümü sağlayacak w_R^k vektörü ile değiştirilirse, problem Denklem 3.34'teki gibi olur.

$$\|E_k \Omega_k - d_k w_T^k \Omega_k\|_F^2 = \|E_k^R - d_k w_R^k\|_F^2 \quad (3.34)$$

Bu çözüm orijinal problemimiz ile aynı hatayı oluşturmalarına rağmen, bu hatayı iki farklı kısma ayırarak ifade eder, doğrudan svd ile çözülür. İlki sinyallere ilişkin hatayı, ikincisi ise diğer örneklere ilişkin hatayı göstermektedir.

E_k^R matrisi, TDA yöntemi kullanılarak $U\Delta V^T$ dönüşümü ile üç farklı matrise ayrıştırılır. Bu sayede U matrisinin ilk sütununda d_k atomunun güncellenmiş hali $\widetilde{d}_k$ atomu, V matrisinin birinci sütununun $\Delta(1,1)$ ile çarpılması ile w_R^k vektörü elde edilmektedir. D bu işlemler sırasında kullanılan sözlüktür ve sütunları normalize edilmiştir.

Denklem 3.35'teki iteratif yöntem ise, alternatif bir çözüm sunmaktadır. İfadedeki işlemlerin birkaç kez tekrarlanması ve ardından ölçeklenmesi ile, d_k atomunun güncellenmiş hali $\widetilde{d}_k$ atomu ve w_R^k katsayı vektörü bulunmaktadır (Aharon ve ark., 2006; Rubinstein ve ark., 2012).

$$\widetilde{d}_k = \frac{E_k^R w_R^k{}^T}{w_R^k w_R^k{}^T}, \quad w_R^k = \frac{\widetilde{d}_k^T E_k^R{}^T}{\widetilde{d}_k^T \widetilde{d}_k} \quad (3.35)$$

Sabit sözlüklü seyrek kodlama problemi olan ℓ_1 ; düzenlenmiş lineer en küçük kareler (ortaya çıkan çözümü daha da sınırlandırmak için düzenlileştirme kullanırken en küçük kareler problemini çözmek için bir yöntem ailesidir) problemidir. Bu problemin çözümü ile alakalı metotlar yumuşak eşikleme (x sinyalinin belli bir değerden yüksek olduğu durumda bir değere eşitlenmesi yerine $\text{sgn}(x)(|x| - t)$ gibi bir fonksiyonla eşikleme yapılmasıdır) ile inişin (Gradyan düşüşünün-descent) koordine edilmesine dayanmaktadır (Fu, 1998; Friedman ve ark., 2007). Sütunlar arasında korelasyon düşük olduğunda bu metotlar oldukça etkili çalışmaktadır. Fakat öğrenilmiş sözlükler üzerindeki sütunlar genelde yüksek korelasyona (bağımlılığa) sahiptir, LARS-Lasso (İstatistikte, en küçük açılı regresyon (LARS)), doğrusal regresyon modellerini (basit doğrusal regresyon, çoklu doğrusal regresyon vb.) yüksek boyutlu verilere uydurmak için bir algoritmadır. İstatistik ve makine öğreniminde, LASSO (en az mutlak büzülme ve seçim operatörü), ortaya çıkan istatistiksel modelin tahmin doğruluğunu ve yorumlanabilirliğini artırmak için hem değişken seçimini hem de düzenlemeyi gerçekleştiren bir regresyon analizi yöntemidir. LASSO algoritmasının Cholsky-tabanlı implementasyonları (Choelsky ayrıştırma metodu, bir Hermitian, pozitif-tanımlı

matrisin daha düşük bir üçgen matrisin ve bunun eşlenik devrikinin ürününe ayrıştırılmasıdır, bu da verimli sayısal çözümler için yararlıdır), tüm regülarizasyon (veri setine problemin çözümü için veri ekleme veya overfitting (ezberleme) problemini engellemek için kullanılır) yolunu sağlayan bir eşyerellik (bir topolojik uzaydan diğerine iki sürekli fonksiyon homotopik (eşyerel) olarak adlandırılır) metodudur (Osborne ve ark., 2000; Efron ve ark., 2004). Burada, λ 'nın tüm mümkün değerleri hesaplanabilmektedir. Bu yaklaşım daha yüksek başarıyı sağlarken, en az yumuşak eşikleme yaklaşımları kadar hızlı olmaktadır.

3.4.8. Sözlük Öğrenme ile Görüntü İşleme Uygulamaları

Sözlük öğrenmenin kullanıldığı bazı görüntü işleme aşağıdaki gibi verilebilir.

- Gürültü giderme
- Görüntü sıkıştırma
- Görüntü ayrıştırma
- Görüntü geri çatma
- Yüz tanıma
- İç boyama
- Manyetik rezonans görüntüleme (MRI)
- Görüntü restorasyonu

3.5. Görüntü İşleme

Bir, iki ya da üç boyutlu bir dijital görüntünün bilgisayar aracılığıyla işlenmesine “görüntü işleme” denilmektedir. İşlem sonucu da genellikle yeni bir görüntüdür. Durağan görüntüler üzerinde işlem yapılabileceği gibi, video ve animasyonlar üzerinde de işlemler yapılabilmektedir. Dijital görüntü işleme teknikleri sayesinde görüntü iyileştirme (Bertalmio ve ark., 2000), görüntü sıkıştırma (Wang ve ark., 2017), biyometrik tanıma (Ali ve ark., 2016), otomatik yüz tanıma (Mery ve Bowyer, 2015), araç takibi (Balaji ve Karthikeyan, 2017), obje veya nesne sınıflandırma (Kumar ve ark., 2011) gibi işlemler yapılabilmektedir (Kuruville ve ark. 2016).

Görüntü işlemede iki boyutlu görüntü $f(x,y)$ olarak gösterilmektedir. Her $f(x,y)$ noktasına resmin (x,y) koordinat noktasındaki piksel değeri verilir.

Günümüzde görüntü işleme; segmentasyon (Haralick ve ark., 1985), bilgisayar grafikleri (Paquette, 1999), görüntü zenginleştirme (Rangayyan, 2000), görüntü kaydı ve mozaikleme, nesne algılama ve izleme, kamera modelleri, stereo görüntü gibi alanlarda (Kang, 2007), görüntü birleştirme (Kang, 2007), bilgisayar oyunları (Magdics ve ark., 2013), gürültü giderme (Kaur ve ark., 2014), süper çözünürlük (Yue ve ark., 2016), obje ve insan takibi (Balaji ve ark., 2017) vb. farklı alanlarda kullanılmaktadır.

Görüntü işlemede alınan veriler üzerinde önışlem, özellik çıkarma ve sonuç aşaması (sınıflandırma, kümeleme, yorumlama vb.) olmak üzere temel üç işlem aşaması uygulanmaktadır (Kang, 2007). Önışlem aşamasında, alınan görüntüler üzerinde daha sonraki işlem aşamalarını zorlaştıran bozulmalar, hatalı alan bilgileri gibi istenmeyen verilerin temizlenmesi, görüntüdeki nesnelere ait kenar bilgilerinin çıkarılması, resmin analizini kolaylaştırmak için resmin iyileştirilmesinin yapılması, görüntüdeki farklı nesnelerin ayrıştırılması için görüntünün başka koordinat düzlemlerine taşınması (dönüşüm) gibi işlemler yapılmaktadır. Tez kapsamında kenar bulma, bulanıklaştırma ve dönüşüm işlemleri uygulanmış; elde edilen verilerden özellik çıkarılarak sınıflandırma işlemi gerçekleştirilmiştir.


Görüntü işlemedeki temel işlemlerden olan önışlem aşamasında genel olarak, sonraki aşamalar için görüntünün hazır hale getirilmesi için işlemler yapılmaktadır. Önışlem aşamasındaki kenar bulma, görüntü parlaklığının keskin bir şekilde değiştiği veya süreksizliklerin olduğu, noktaların “kenar” adı verilen çizgi parçası halinde elde edilmesi ve böylelikle nesnelerin sınırlarının belirlenmesidir. Kenar bulma, görüntü işleme, makine görmesi ve bilgisayarla görme uygulamalarında temel bir araçtır. Prewitt, Sobel, Roberts, Laplacian ve Canny en bilinen ve yaygın kullanılan kenar tespiti yöntemleridir (Savant, 2014).

Canny kenar bulma operatörü, görüntülerdeki çok kenarlı şekilleri algılamak ve kenarları çıkarmak için çok aşamalı bir algoritma kullanan kenar algılama operatörüdür. 1986 yılında John F. Canny tarafından geliştirilmiştir (Şekil 3.11) (Canny, 1986; Muralidharan ve ark., 2014).



Şekil 3.11. (a) Orijinal Resim, (b) Canny Kenar Bulma Operatörünün Çıktısı

Görüntü işlemede bulanıklaştırmanın amacı, piksel yoğunluğundaki (pixel density) hızlı geçişleri ortalamaktır. Görüntünün bulanıklaştırılması veya düzgünleştirilmesi, görüntüde parazit (istenmeyen bozulmalar) oluşturabilecek “dışlayıcı (outlier)” pikselleri kaldırır. Bulanıklaştırma, görüntüye alçak geçiren bir filtre (low-pass filter) uygulama örneğidir ve kenar bulma gibi çok yaygın kullanılan bir ön işlemdir (El Abadi, 2018). Bulanıklaştırma için birçok farklı yöntem bulunmaktadır. Bulanıklığı gerçekleştirmek için kullanılan yaygın filtre türleri ortalama filtre (mean filter), ağırlıklı ortalama filtre, ortanca (medyan) filtre (median filter) ve Gauss filtresidir. Tez kapsamında bulanıklaştırma için medyan filtre kullanılmıştır. Şekil 3.12’de medyan filtresi ile yapılan bir bulanıklaştırma sonucu verilmiştir.



Şekil 3.12. (a) Orijinal resim, (b) Medyan filtre uygulanmış resim

“Ortanca” (median) bulanıklaştırma filtresi belirlenen komşuluk alanında ortanca değeri hesaplar (Şekil 3.13). Belirlenen komşuluk alanındaki piksel değerleri küçükten büyüğe doğru sıralandıktan sonra, ortadaki değer alınarak, ilgili piksel değeri olarak yazılır. Bu hesaplama yeni bir değer oluşturmaz ve komşulukta temsil edilmeyen bir piksel sonucu etkilemez. Böylece filtre, kenarları korur ve köşeleri yuvarlar. Bu

filtre özellikle tuz ve karabiber gürültüsünü azaltmak ve fotoğraflardaki çizikleri silmek için kullanılır.

223	186	114	
204	161	106	106 114 138 161 186 194 204 219 223
219	194	138	

Şekil 3.13. 3x3'lük Medyan bulanıklaştırması işleminde ortanca değer seçimi.

Önişlem adımlarından biri de görüntüye farklı dönüşüm yöntemlerinin uygulanmasıdır. Bir görüntü dönüşümü, görüntüyü bir uzaydan diğerine dönüştürmek için uygulanabilir. Bir görüntü uzaysal (spatial domain) ya da frekans uzayında (frequency domain) gösterilebilir. Günlük hayatta kullandığımız sayısal resimler uzaysal uzayda oluşturulur. Buna karşın, görüntünün birçok farklı frekanslı bileşenden oluştuğu kabul edilir ve bu bileşenleri elde etmek için frekans uzayına geçiş yapılır. Böylece görüntüyü frekans uzayında görüntülemek, uzaysal alanda kolayca algılanamayan özelliklerin tanımlanmasını sağlar. Bu amaçla kullanılan bazı görüntü dönüşümleri şunlardır (Kuruvilla ve ark., 2016):

- Görüntüdeki çizgileri bulmak için kullanılan Hough Dönüşümü
 - Fan ışını ve paralel ışın yansıtma verilerinden görüntüleri yeniden oluşturmak için Radon Dönüşümü
 - Görüntü ve video sıkıştırmada kullanılan Kesikli Kosinüs Dönüşümü (Discrete Cosine)
 - Filtreleme ve frekans analizinde kullanılan Ayırık Fourier Dönüşümü (Discrete Fourier)
 - Gürültü temizleme vb. işlemler için kullanılan Dalgacık Dönüşümü (Wavelet)
- Dönüşüm için kullanılan yöntemlerden biri Hough Çember Dönüşümü'dür. Dijital görüntü işlemede kullanılan bu yöntem, bir resimdeki dairesel nesneleri algılayan temel bir tekniktir (Yadav ve ark., 2014).


Hough Çember Dönüşümü, dairesel nesneleri algılamak için bir özellik çıkarma tekniğidir. Hough Dönüşümü'nün özel bir uygulamasıdır. Hough Dönüşümü, belirli bir şekil sınıfı içindeki objelerin örneklerini bir oy verme işlemi ile bulmaktadır. Bu oylama

işlemi, bir nesne adayının, Hough Dönüşümünü hesaplamak için algoritma tarafından oluşturulmuş olan bir akümülatör ile yerel maksimum olarak elde edildiği bir parametre uzayında gerçekleştirilmektedir (Yadav ve ark., 2014). Tekniğin amacı kusurlu görüntü girişlerindeki dairesel nesneleri bulmaktır. Daire olabilecek alanlar, Hough parametre alanındaki “oylama” ile üretilir ve ardından bir akümülatör ile yerel maksimumu seçerler (Daugman, 2004). Şekil 3.14’de Hough Çember Dönüşümü ile yapılmış bir işlem sonucu gösterilmektedir.




Şekil 3.14. Hough dönüşümü ile iris tespiti. (a) orijinal resim, (b) Hough Çember Dönüşümü ile bulunan dairesel alan

Hough gibi dairesel dönüşüm yapılan yöntemlerde, dairesel alan elde edildikten sonra, bu alanın işlenebilmesi ve daha kolay analiz edilebilmesi için koordinat düzleminde bir işlem gerekmektedir. Çünkü dairesel işlem sonunda elde edilen nesne yuvarlaktır ve iki boyutlu matris formatında işlenmesi mümkün değildir. Dairesel alanı matris formatında açmak için yapılan bu işleme “Kartezyen koordinat düzleminde Polar koordinat düzlemine geçiş” denilmektedir (Şekil 3.15) (Torrence ve Torrence, 2019).



Şekil 3.15. Kartezyen koordinattan polar koordinata dönüşüm. (a) orijinal resim, (b) polar koordinat düzleminde gösterimi (Belcher & Du, 2009).

Bir görüntü histogramı, dijital bir resimdeki tonal dağılımın grafik gösterimi olarak işlev gören bir histogram türüdür. Her ton değeri için piksel sayısını gösterir. Kontrast, bir nesnedeki (veya bir görüntüdeki veya ekrandaki temsilindeki) ayırt edebilir parlaklık veya renk farkını belirtir. Histogram eşitlemesi, görüntünün histogramını kullanarak kontrast ayarının yapılmasını sağlayan ve görüntü işlemede kullanılan bir yöntemdir. Bu yöntem, görüntü yakın kontrast değerlerine sahip ise görüntünün genel kontrastını artırır. Bu ayar sayesinde yoğunluklar histogramda daha iyi dağıtılabılır ve düşük yerel kontrast alanlarının daha yüksek bir kontrast değerine çıkarılmasını sağlar (Şekil 3.16) (Ali ve ark., 2016).




Şekil 3.16. Histogram eşitleme. (a) orijinal resim, (b) histogram eşitlenmiş hali


Uyarlanabilir eşik, istenen ön plandaki görüntü nesnelerini, her bölgenin piksel yoğunluklarındaki farka dayalı olarak arka plandan ayırmak için kullanılır. Küresel eşikleme, görüntüdeki tüm pikseller için sabit bir eşik kullanır ve bu nedenle, yalnızca giriş görüntüsünün yoğunluk histogramı, istenen konu(lar)a ve arka plan(lar)a karşılık gelen düzgün bir şekilde ayrılmış tepe noktaları içeriyorsa çalışır. Bu nedenle, örneğin güçlü bir aydınlatma gradyanı içeren görüntülerle başa çıkamaz. Genelde uyarlanabilir eşiklemede ortalama filtre kullanılır, bazı durumlarda ise ortalama filtre-C kullanılır, burada C sabittir.

Öte yandan, yerel uyarlanabilir eşik, yerel komşuluktaki yoğunluk değerlerinin aralığına bağlı olarak her piksel için ayrı bir eşik seçer. Bu, küresel yoğunluk histogramında belirgin zirveler içermeyen bir görüntünün eşiklenmesine izin verir. Basit eşiklemede eşik değeri globaldir, yani görüntüdeki tüm pikseller için aynıdır. Uyarlanabilir eşikleme, eşik değerinin daha küçük bölgeler için hesaplandığı yöntemdir


ve bu nedenle, farklı bölgeler için farklı eşik değerleri olacaktır (Şekil 3.17) (Bakshi ve ark., 2011).




(a)



(b)



(c)




(d)

Şekil 3.17. Şekil uyarlanabilir eşik örneği. (a) orijinal görüntü, (b) orijinal görüntüye global eşikleme uygulanmış hali, (c) orijinal görüntüye 7'lik komşulukta ve $C=7$ olmak üzere uyarlanabilir eşikleme ve (d) orijinal görüntüye 75'lik komşulukta ve $C=10$ olmak üzere uyarlanabilir eşikleme uygulanması.

Şekil 3.17'den de takip edilebildiği üzere global eşikleme orijinal görüntü üzerinde oldukça kötü bir sonuç vermektedir. Bunun sebebi ise sayfa üzerinde oluşan aydınlatmadır. Şekil 3.17-c görüntüsü ise Şekil 3.17-d'den daha iyi bir sonuç vermiştir. Buradaki temel neden ise, geniş komşuluk kullanılmasıdır ve bu yüzden Şekil 3.17-d'deki görüntü özellikle ışık yoğunluğunun değiştiği alanlarda kötü sonuç üretmiştir.

İkili (binary) görüntülerde genişletme (dilation), temel morfolojik işlemlerden biridir (Şekil 3.18). Genişletme, bir görüntüdeki nesnelerin sınırlarına pikseller ekler. Bir görüntüdeki nesnelere eklenen piksel sayısı, görüntüyü işlemek için kullanılan yapılandırma ögesinin boyutuna ve şekline bağlıdır (Tambe ve ark., 2013).



Şekil 3.18. Görüntü genişletme. (a) orijinal A görüntüsü, (b) A görüntüsünün 3x3 boyutlarında bir yapılandırma ögesi (S) ile genişletilmiş hali

3.6. Sınıflandırma

“Sınıflandırma”, makine öğrenimi ve istatistikte, kategori üyeliği bilinen gözlemleri (veya örnekleri) içeren bir eğitim seti temelinde yeni bir gözlemin bu kategorilerden (alt popülasyonlar) hangisine ait olduğunu belirleme problemidir (Alpaydin, 2014). Yeni gözlemin hangi sınıfa ait olduğunu belirlemede farklı yöntemler kullanılmaktadır. Bu amaçla, genellikle yeni gözlem ile eğitim setindeki örnekler farklı yöntemlerle karşılaştırılarak, en çok benzerlik gösterenler aynı kategoriye atanmaktadır. Karşılaştırma için Hamming (Sathish, 2012), Öklid (Latifa ve ark., 2017), Manhattan (Latifa ve ark., 2017) gibi uzaklık ölçümleri sıklıkla kullanılmaktadır.

1) Hamming uzaklığı: Hamming uzaklığı, vektör bazlı bir karşılaştırma algoritmasıdır. Aynı uzunluktaki iki dizinin farklı elemanlarının sayısıdır. Yani bir dizinin diğer diziden ne kadar farklı olduğunu gösterir. Hamming uzaklığının hesaplanmasına ait bir örnek Şekil 3.19’da verilmiştir. Şekil 3.19’da A ve B dizilerinin soldan itibaren bakılacak olursa 3, 7 ve 9. Elemanları birbirlerinden farklıdır ve bu iki dizgi arasındaki Hamming uzaklığı bu nedenle 3’tür.

<i>A</i>	1	0	1	1	0	0	1	0	0	1
			⇕				⇕		⇕	
<i>B</i>	1	0	0	1	0	0	0	0	1	1

Şekil 3.19. Hamming uzaklığının hesaplanması

Herhangi bir uygulamada iki verinin birbirine olan benzerlik ya da farklılıklarının bulunmasında, yalnızca uzaklık ölçümleri değil, ayrıca farklı benzerlik ölçütleri de kullanılabilir. Yapısal Benzerlik İndeksi (YBİ) (SSIM-Structural Similarity Index), Jaccard İndeksi, Kosinüs Benzerliği (Cosine Similarity) gibi literatürde kullanılan farklı benzerlik ölçütleri bulunmaktadır.

2) Yapısal Benzerlik İndeksi (YBİ): YBİ (SSIM-Structural Similarity Index Measure), dijital televizyon ve sinematik resimlerin yanı sıra diğer dijital resim ve video türlerinin algılanan kalitesini tahmin etmek için bir yöntemdir. Temel model, Austin'deki Texas Üniversitesi'ndeki Görüntü ve Video Mühendisliği Laboratuvarı (LIVE) ve New York Üniversitesi'ndeki Hesaplamalı Görme Laboratuvarı (LCV) ile birlikte geliştirilmiştir. Modelin diğer varyantları, Waterloo Üniversitesi Görüntü ve Görsel Hesaplama Laboratuvarı'nda geliştirilmiş ve ticari olarak pazarlanmıştır (Wang ve ark., 2004).

YBİ metriği, iki görüntü arasındaki benzerliği ölçmek için kullanılır. YBİ tam referans metriğidir. Başka bir deyişle, görüntü kalitesinin ölçülmesi veya tahmin edilmesi, referans olarak sıkıştırılmamış veya bozulmamış bir başlangıç resmine dayanır. YBİ, tepe sinyal-gürültü oranı (PSNR-Peak Signal-to-Noise Ratio) ve Ortalama Kare Hatası (OKH) (MSE-Mean Squared Error) gibi geleneksel yöntemlerde iyileştirmek için tasarlanmıştır (Horé ve Ziou, 2010).

YBİ ilk olarak Evrensel Kalite Endeksi (UQI-Universal Quality Index) veya Wang-Bovik Endeksi olarak adlandırılmıştır ve 2001 yılında Zhou Wang ve Alan Bovik tarafından geliştirilmiştir. Daha sonra, Hamid Sheikh ve Eero Simoncelli beraber çalışarak, YBİ'nin güncel halini ortaya koymuşlardır ve Nisan 2004'te IEEE Görüntü İşleme İşlemleri'nde yayınlanmıştır (Wang ve ark., 2004).

YBİ, negatif olmayan, görülemeyen değerlerin ayırt edilmesini ve simetri özelliklerini karşılar, ancak üçgen eşitsizliğini karşılamaz ve bu nedenle bir mesafe metriği değildir. Bununla birlikte, belirli koşullar altında YBİ, bir uzaklık ölçüsü olan normleştirilmiş bir kök OKH ölçüsüne dönüştürülebilir (Dosselmann ve Yang, 2011). Böyle bir metriğin karesi dışbükey değildir, fakat yerel olarak dışbükey ve yarı-konvektir (Brunet ve ark., 2012) ve YBİ'i optimizasyon için uygulanabilir bir hale getirir.

YBİ görüntü sıkıştırma, görüntü restorasyonu ve desen tanıma alanlarında kullanılmaktadır. YBİ, bir görüntüdeki iki pencere (x ve y) arasında hesaplanır. $N \times N$ boyutlarındaki x ve y pencereleri arasındaki YBİ formülü Denklem 3.36'da verilmiştir.

$$YBİ(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (3.36)$$

Burada x ve y karşılaştırılacak 2 veri olmak üzere; μ_x , x 'in ortalaması; μ_y , y 'nin ortalaması; σ_x^2 x 'in varyansı; σ_y^2 y 'nin varyansı; σ_{xy} x ve y 'nin kovaryansı, $c_1 = (k_1L)^2$ ve $c_2 = (k_2L)^2$ zayıf bölen durumunda bölme işlemini kararlılaştıran iki değişken, L piksel değerlerinin dinamik aralığı (tipik olarak $2^{\text{piksel sayısı}} - 1$ şeklinde hesaplanır), $k_1 = 0.01$ ve $k_2 = 0.03$ olarak kullanılır (sabit değer olarak).

YBİ formülü x ve y gibi 2 örnek arasında parlaklık (l), kontrast (c) ve yapı (s) olarak üç farklı karşılaştırma ölçümüne dayanmaktadır (Denklem 3.37, 3.38, 3.39).

$$l(x, y) = \frac{(2\mu_x\mu_y + c_1)}{(\mu_x^2 + \mu_y^2 + c_1)} \quad (3.37)$$

$$c(x, y) = \frac{(2\sigma_{xy} + c_2)}{(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (3.38)$$

$$s(x, y) = \frac{(\sigma_{xy} + c_3)}{(\sigma_x\sigma_y + c_3)} \text{ ve } c_3 = c_2/2 \quad (3.39)$$

Bu üç ölçüm daha sonra ağırlıklandırılmış çarpıma sokulur (Denklem 3.40)

$$YBİ(x, y) = [l(x, y)^\alpha \cdot c(x, y)^\beta \cdot s(x, y)^\gamma] \quad (3.40)$$

Eğer α, β, γ 1'e eşitlenirse Denklem 3.36'daki halini alır.

3) Öklid mesafesi: Öklid uzayında iki nokta arasındaki Öklid mesafesi, iki nokta arasındaki bir doğru parçasının uzunluğudur. Pisagor teoremi kullanılarak noktaların Kartezyen koordinatlarından hesaplanabilir, bu nedenle bazen Pisagor mesafesi olarak da adlandırılır.

Nokta olmayan iki nesne arasındaki mesafe, genellikle iki nesneye olan nokta çiftleri arasındaki en küçük mesafe olarak tanımlanır. Formüller, bir noktadan bir çizgiye olan mesafe gibi farklı türdeki nesneler arasındaki mesafeleri hesaplamak için bilinmektedir. İleri matematikte, uzaklık kavramı soyut metrik uzaylara genelleştirilmiştir ve Öklid dışındaki diğer mesafeler incelenmiştir. İstatistik ve

optimizasyondaki bazı uygulamalarda, mesafenin kendisi yerine Öklid mesafesinin karesi kullanılır (Sanchez-Avila ve Sanchez-Reillo, 2005).

Doğru üzerindeki herhangi iki nokta arasındaki mesafe, koordinatlarının sayısal farkının mutlak değeridir. Böylece, p ve q bir çizgi üzerinde iki nokta ise, aralarındaki mesafe Denklem 3.41'deki gibi verilir.

$$d(p, q) = |p - q| \quad (3.41)$$

Aynı değeri veren ancak daha yüksek boyutlara daha kolay genellenen daha karmaşık bir formül Denklem 3.42'de verilmiştir.

$$d(p, q) = \sqrt{(p - q)^2} \quad (3.42)$$

İki boyutlu uzay için Öklid düzleminde, p noktasının Kartezyen koordinatları (p_1, p_2) olsun ve q noktasının koordinatları (q_1, q_2) olsun. Daha sonra p ve q arasındaki mesafe Denklem 3.43'teki gibi verilir.

$$d(p, q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2} \quad (3.43)$$

4) Ortalama Kare Hatası (OKH): Gözlenmeyen bir miktarı tahmin etmek için bir prosedürün Ortalama Kare Hatası (OKH) (MSE – Mean Squared Error) veya Ortalama Kare Sapması (OKS) (MSD – Mean Standard Deviation), hataların karelerinin ortalamasını ölçer - yani, tahmin edilen değerler ile hesaplanan değerler arasındaki ortalama kare farkı gerçek değerini hesaplar. OKH, kare hata kaybının beklenen değerine karşılık gelen bir risk fonksiyonudur (Jung ve ark., 2016).

İki görüntü $x(n, m)$ ve $y(n, m)$ arasındaki OKH Denklem 3.44'te verilmiştir:

$$OKH = \frac{1}{MN} \sum_{n=1}^M \sum_{m=1}^N [x(n, m) - y(n, m)]^2 \quad (3.44)$$

3.7. Python Programlama Dili ve OpenCV

Python, nesne yönelimli (sınıf yapısını destekleyen), multi-paradigmalı (birçok programlama dilini destekleyen) ve yüksek seviyeli bir programlama dilidir. Dilin yapısı gündelik konuşma diline oldukça yakındır ve diğer programlama dillerinden farklı olarak girintileme hatalarını da grammer hatası (syntax error) olarak kabul eder (Anonymous, 2021).

Dilin tasarımcısı Guido van Rossum'dur ve Python, şu anda Python yazılım vakfı tarafından geliştirilmektedir. İlk olarak 1991 yılında yayınlanmıştır. En son kararlı sürümü 3.9.1 ve 2.7.18'dir. Python, platform bağımsız (cross-platform) bir dil olduğu için uygun yorumlayıcısının bulunduğu ve yazıldığı sürüm ile Python yorumlayıcısının sürümünün aynı olduğu her platformda çalıştırılabilir (Anonymous, 2021).

Python programlama dili hakkında internette oldukça fazla bilgi bulunabilir. Açık kaynak kodlu olması sebebi ile karşılaşılabilecek problemler hakkında geliştirici topluluğuna ulaşmak ve yardım almak da oldukça kolaydır (Anonymous, 2021).

Python, açık kaynak olduğu için geliştirici sayısı oldukça fazladır. Hemen hemen her alanla alakalı bir Python Kütüphanesi bulunmaktadır. Hızlı programlanabilmesi ve bu ek kütüphanelerin yardımı ile bilimsel çalışmalarda yoğun olarak kullanılmaktadır. Python dili ile kullanılan bazı kütüphaneler aşağıda verilmiştir (Anonymous, 2021).

1) Scikit kütüphanesi: Scikit-learn (eski adıyla scikits.learn) Python programlama dili için kullanılan ücretsiz bir yazılım makinesi öğrenme kütüphanesidir. Destek Vektör Makinesi (DVM) (SVM-Support Vector Machine), Rastgele Orman (RO) (RF-Random Forest), Gradyan Artırma (GA) (GB-Gradient Boosting) ve DBSCAN (Density-Based Spatial Clustering of Applications with Noise) dahil çeşitli sınıflandırma, regresyon ve kümeleme algoritmalarına sahiptir ve Python sayısal ve bilimsel kütüphaneleri NumPy ve SciPy ile birlikte çalışacak şekilde tasarlanmıştır.

2) Matplotlib Kütüphanesi: Python programlama dili ve sayısal matematik uzantısı olan NumPy için bir çizim kütüphanesidir. Tkinter, wxPython, Qt veya GTK+ gibi genel amaçlı GUI araç takımlarını kullanarak uygulamaları yerleştirmek için nesne yönelimli bir API sağlar. SciPy kütüphanesi, Matplotlib'den yararlanır.

3) SciPy Kütüphanesi: Bilimsel hesaplama için kullanılan açık kaynak kodlu bir Python kütüphanesidir. Optimizasyon, lineer cebir, entegrasyon, interpolasyon, Hızlı Fourier Dönüşümü (HFD) (FFT-Fast Fourier Transform), sinyal işleme, resim işleme,

adi diferensiyel denklemler gibi birçok modülü içeren, bilimsel çalışmalarda ve mühendislik alanında kullanılan oldukça geniş bir kütüphanedir.

4) Sporcio kütüphanesi: Seyrek Optimizasyon Araştırma Kodu (SPORCO), sparsity regülasyonu ile optimizasyon problemlerini çözmek için bir Python paketidir. Esas olarak seyrek kodlama, evrişimli seyrek kodlama ve sözlük öğrenimi dâhil olmak üzere sözlük öğrenme problemlerinden oluşur, ancak Toplam Değişken Düzenlemesi (TDD) (TVR-Total Variation Regularisation) ve Sağlam Temel Bileşen Analizi (STBA) (RPCA-Robust PCA) gibi diğer problemleri de destekler. Mevcut sürümdeki optimizasyon algoritmaları, Çarpanların Alternatif Yön Yöntemi'ne (ADMM-Alternating Direction Method of Multipliers) veya Hızlı Yinelemeli Büzülme-Eşik Algoritmasına (FISTA-Fast Iterative Shrinkage-Thresholding Algorithm) dayanmaktadır.

5) Numpy Kütüphanesi: Büyük, çok boyutlu diziler ve matris desteği içeren açık kaynak kodlu bir Python kütüphanesidir. Bu desteğin yanı sıra, diziler ve matrisler üzerinde çalışan yüksek seviyeli birçok matematik fonksiyonunu içerir. Ayrıca SciPy kütüphanesinin verimli kullanılabilmesi için gereklidir.


Python ve kütüphaneleri haricinde görüntü işleme için kullanılan bir diğer yazılım da OpenCV'dir. OpenCV kütüphanesi, açık kaynak kodlu bilgisayarla görme kütüphanesidir. Yapısında, bilinen bilgisayarla görme algoritmalarının çoğu bulunur. Bu sayede bu alanda çalışanlar, sıfırdan bu algoritmaları gerçeklemek yerine, çalışmalarını daha hızlı bir şekilde koda dökerek sonuçları değerlendirebilirler. OpenCV açık kaynak kodlu olması sebebi ile geniş bir geliştirici kitlesine ve oldukça ayrıntılı bir dokümantasyona sahip bir kütüphanedir. Bu sayede kullanımı olabildiğince basittir. Ayrıca kütüphane C++'la yazılmasına rağmen, Python'la kullanılabilmesi için de yardımcı kütüphaneleri bulunmaktadır. OpenCV kütüphanesi platform bağımsız olması sebebi ile MacOS, Windows ve Unix ortamlarında kullanılabilmektedir. Bu da tercih sebeplerinden birisidir (Anonymous, 2021)

4. ÖNERİLEN YÖNTEM


4.1. Kullanılan Veriseti

Yapılan çalışmada kullanılan veri seti Biometric Ideal Test tarafından geliştirilen CASIA Iris Görüntü Veri tabanıdır (CASIA-Iris V1). Uluslararası biyometri topluluğunun kullanımına açılmıştır ve 2002'den bu yana CASIA-IrisV1'den CASIA-IrisV4'e güncellenmiştir. 70 ülkede 3000'den fazla kullanıcı CASIA-Iris'i alarak, çalışmalarında kullanmıştır (Alrifae ve ark., 2017; Tan, 2019; CASIA Iris veritabanı, 2020).

Tez çalışması, CASIA-Iris V1 veri setinde bulunan 108 farklı kişiye ait iris görüntüleri kullanılarak yapılmıştır. Veri setinde, her kişiye ait 7 farklı iris resmi bulunmaktadır. Bunların 3 adeti birinci oturumda alınan, 4 adeti ise ikinci oturumda alınan aynı gözden alınan iris resimleridir. Veritabanında böylelikle 108 kişiye ait toplam 756 ait iris görüntüsü bulunmaktadır. Resimler Bmp formatında ve 320x240 piksel boyutundadır. Resimler NIR kamera ile alındıkları için gri-seviye görüntülerdir. Bu yüzden görüntülere gri seviye dönüşümü yapılmamıştır. Veritabanında kayıtlı tüm iris görüntülerinde, iris ve gözbebekleri eşmerkezlidir. Resimlerin gözbebeği kısımları, veri tabanı için geliştirilen kamera tarafından bir yoğunluk maskesi kullanılarak değiştirilmiştir. Bu değişimin nedeni, kameranın iris görüntülerini yakalamak için kullandığı kızıl ötesi aydınlatma bilgilerinin verilmek istenmemesidir (Tan, 2004). CASIA-Iris V1 veritabanından örnek iris görüntüleri Şekil 4.1'de verilmiştir.



Şekil 4.1. CASIA-Iris V1 örnek iris resimleri (CASIA-Iris V1)




Şekil 4.2. Önerilen sistemin görüntü işleme akış şeması

Tez kapsamında irisin lokalizasyonu ve önişlem adımları için, görüntü işleme metotlarından bulanıklaştırma, kenar bulma ve Hough Dairesel Dönüşüm yöntemleri kullanılmıştır. Daha sonra polar düzleme dönüşüm yapılarak görüntü, lineer bir düzleme aktarılmıştır. Bu sayede düzleştirilmiş görüntü üzerinde çalışılarak, sonuçların tutarlı olması için tüm resimler uygun bir büyüklüğe göre yeniden boyutlandırılmıştır. Bu aşamadan sonra resimlere sözlük öğrenmesi uygulanarak irise ait özellikler belirginleştirilmiş, elde edilen özellikler YBİ, HU, OKH ve Öklid uzaklığı metriklerine göre karşılaştırılarak sınıflandırma yapılmıştır. Sınıflandırma aşaması bittikten sonra, resimler uygun bir kodlama ile veritabanında saklanarak, karşılaştırma ve tanılama işlemleri bu veritabanı kullanılarak gerçekleştirilmiştir. Her bir son işlem adımı ve detaylı bilgiler Şekil 4.2’de verilen sırada açıklanmıştır.

4.2. K-TDA ile İris Özelliklerinin Vurgulanması

CASIA-Iris V1 veritabanından alınan görüntülerden öncelikle iris yerinin belirlenmesi için geçici bir template görüntü üretilmiştir. Böylece template kullanılarak iris yeri tespit edilip, belirlenen noktalara göre iris orjinal görüntüden çıkarılmış ve K-TDA için orijinal görüntü bozulmamıştır. İris tespiti için template görüntüde öncelikle 27x27 boyutunda ortanca filtresi uygulanmış ve görüntü bulanıklaştırılmıştır (Şekil 4.3). Daha sonra, gözbebeği alt-üst sınır değerleri belirlenerek, iris sınırları yaklaşık olarak belirlenmiştir.




Şekil 4.3. Filtre uygulaması (a) giriş resmi, (b) ortanca filtresi uygulanmış hali


Görüntü bulanıklaştırmadan sonra gözbebeği için eşik değeri belirlenmiştir. Bu eşik değeri görüntüden görüntüye histograma bağlı olarak değişmektedir. Bu eşik değeri kullanılarak görüntü siyah beyaz hale getirilmiştir. Daha sonra gözbebeği sınırları bu

siyah beyaz görüntü üzerinde bulunmak üzere tüm görüntünün (0,0) (başlangıç) piksellerinden başlayarak bir tarama gerçekleştirilmiştir. Kenar filtresi uygulamak yerine sağa doğru giden bir döngü ile gözbebeği sınırları bulunmuş ve beyaz bir çember içine alınmıştır. Geleneksel iris tanıma uygulamalarında bu adımda bir kenar bulma algoritması uygulanır, Kenar bulma algoritmasının hesaplama maliyetinden kurtulmak için böyle bir yol izlenmiştir.


Gözbebeği tespiti yapıldıktan sonra, Hough Dairesel Dönüşümü ile irisin alanı belirlenmiştir. Hough Dönüşümü için dinamik çember belirleme parametreleri kullanılmıştır. Belirlenecek çember merkezleri arasındaki minimum uzaklık parametresi dinamik olarak iris yarıçapına bağlı olarak belirlenmiştir. Bu parametreler minimum yarıçap belirleme için görüntünün genişliğinin dörtte biri, maksimum yarıçap için de görüntünün yüksekliğinin yarısı olarak belirlenmiş, iris ve gözbebeği eşmerkezli olduğu için merkez bölgesi ise bir önce adımda bulunan gözbebeği merkezi olarak verilmiştir. Bu sayede her bir iris resmi için gözbebeği merkezine ve gözbebeği boyutuna bağlı olarak görüntüde gözbebeği ve iris sınırları tespit edilmiştir (Şekil 4.4).




(a)



(b)




(c)



(d)

Şekil 4.4. İris tespiti. (a) ortalanca filtre uygulanmış resim, (b) gözbebeği sınırları, (c) tespit edilen gözbebeği, (d) Hough Dairesel Dönüşümü ile belirlenen iris sınırları


Bu aşamadan sonra, template kullanılarak elde edilen iris sınır pikselleri kullanılarak orijinal görüntü üzerinde belirlenen iris yarıçapı ve iris merkezi dikkate alınarak görüntüden iris alanı kesilir. Daha sonra Kartezyen koordinattan polar koordinata geçiş yapılır. Bu sayede elimizdeki görüntü, matris formatında dikdörtgen hale dönüştürülür (Şekil 4.5).



Şekil 4.5. Polar koordinata geçiş. (a) Hough Dairesel Dönüşümü ile belirlenen iris sınırları, (b) iris sınırlarından kesilmiş görüntü, (c) polar koordinatta normalize edilerek, yeniden boyutlandırılmış görüntü


Polar koordinata dönüştürülmüş tüm resimlerin yarıçapı farklı olduğundan ve bu da karşılaştırma için problem yaratacağından tüm görüntüler 256x64 piksel olarak yeniden boyutlandırılmış. Böylece tüm görüntüler aynı boyutlarda standart hale getirilmiştir. Bu işlem esnasında görüntü öznetelikleri değiştirilmemiş olup sadece boyutlar 256x64 olarak ayarlanmış ve sabitleştirilmiştir.

Önişlem aşamalarından geçerek, iki boyutlu matris formatında standart boyutlara getirilen görüntüler normalize edilmiş, daha sonra görüntülerin içinde normal dağılıma sahip gürültülerin giderilmesi ve görüntü zenginleştirme ile irise ait ayırt edici özelliklerin belirginleştirilmesi için K-TDA uygulanmıştır (Şekil 4.6). K-TDA için sözlük atom sayısı, hata hedefi, blok boyutu ve iterasyon sayısı olarak 4 farklı parametre kullanılarak başarı hesaplanmıştır.



Şekil 4.6. K-TDA uygulaması. (a) normalize edilmiş görüntü, (b) K-TDA uygulanmış görüntü

K-TDA ile görüntü ayırt edici özelliklerinin vurgulanması amaçlanmıştır. Her bir resim için bu işlemler yapılmış ve veritabanı dosya düzeni korunarak diske kaydedilmiştir (Şekil 4.7).



Şekil 4.7. Farklı parametre değerleri kullanılarak uygulanan K-TDA çıktı görüntüleri

Bundan sonraki aşamada ise histogram eşitleme yapılarak, görüntülerin son hali elde edilmiştir (Şekil 4.8).




Şekil 4.8. Histogram eşitleme uygulaması. (a) K-TDA uygulanmış görüntü, (b) histogram eşitlenmiş görüntü

Sonraki aşamada ise histogram eşitleme uygulanmış görüntülerden şablon çıkarma işlemi yapılmıştır. Bu işlem için görüntüler, giriş görüntüsünün yüksekliğinin yarısı olacak şekilde kesilmiştir. Bu sayede gözkapağı, kirpik gibi elemanlar elemine edilmiştir. Daha sonra görüntülerden şablon çıkarma işlemi yapılmış ve 256x32 piksel boyutlarında şablonlar elde edilmiştir. Bu işlemin adımları sırası ile şu şekildedir:

1. Görüntüye 7x7 boyutlarında bir ortanca (medyan) filtre uygulanmıştır (Şekil 4.9-b). (İlk işlem adımıdaki filtre template görüntüye uygulanmış, orijinal görüntüye bu adıma kadar hiçbir işlem yapılmamıştır)

2. Daha sonra bulanıklaştırılmış görüntü üzerinde Gauss filtresi ağırlıklarını kullanan 23x23'lük bir pencerede $C=5$ olmak üzere ters çevirilmiş ikili görüntü üretecek şekilde adaptif eşikleme uygulanmıştır. Böylece sonuç görüntüsü siyah-beyaz formata getirilmiştir (Şekil 4.9-c).
3. Daha sonra 3x3'lük bir kare yapısal elemanı ile genişletme yapılmıştır. Karesel elemanın boyutu küçüldükçe işlem zamanı artmaktadır ama karesel eleman ne kadar küçük olursa görüntüdeki en küçük detayları yakalayabilmek o kadar iyi sonuç vereceği için, tez kapsamında karesel elemanın boyutu 3x3 seçilmiştir (Şekil 4.9-d).
4. Genişletme yapılmış görüntü (Şekil 4.8-d) ile orijinal görüntü (Şekil 4.8-a) ikili "ve" işlemine tabi tutulmuştur. Bu işlem sonucunda gri seviye bir görüntü elde edilmiştir (Şekil 4.9-e).
5. Bu aşamadan sonra elde edilen görüntüye Gauss filtresi ağırlıklarını kullanan 3x3'lük bir pencerede $C=5$ olmak üzere ters çevirilmiş ikili görüntü üretecek şekilde uygulanmıştır. Bu aşamada da en küçük detayları yakalayabilmek için pencere boyutu 3x3 seçilmiştir. Bu işlem aşaması sonucunda arka plan siyah zeminde iris bölgeleri beyaz olarak elde edilmiştir (Şekil 4.9-f).



Şekil 4.9. Şablon çıkarma adımları.(a) 256x32 boyutundaki görüntü,(b) ortanca filtre uygulanmış görüntü, (c) birinci adaptif eşikleme sonucu, (d) genişletme sonucu , (e) a ve d görüntülerinin ikili "ve" işleminin sonucu, (f) ikinci adaptif eşikleme sonucu oluşan şablon görüntüsü

Adaptif eşikleme işlemlerinde $C=5$ olarak seçilmiştir. Bunun nedeni farklı blok boyutlarında yapılan işlemlerde en iyi başarı sonuçlarının $C=5$ değerinde elde edilmiş olmasıdır (Çizelge 4.1).

Çizelge 4.1'de YBİ metriği ile yapılan karşılaştırma sonuçları verilmiştir. $C=5$ değeri farklı blok boyutlarında ortalama olarak daha iyi sonuç ürettiği için $C=5$ seçilmiştir.

Çizelge 4.1. Adaptif eşikleme için farklı parametre değerlerinin uygulanması sonucu elde edilen sonuçlar

Blok Boyutu	C=5 için YBİ	C=7 için YBİ
5x5	80.91	70.81
13x13	88.52	90.45
23x23	92.80	94.46
	Ortalama = 87.41	Ortalama = 85.24

Tüm işlemlerden sonra Yapısal Benzerlik İndeksi (YBİ), Öklid Uzaklığı (ÖU), Hamming Uzaklığı (HU) ve Ortalama Karesel Hata (OKH) metrikleri kullanılarak karşılaştırmalar yapılmıştır. Karşılaştırma işleminde, girdi görüntüsü kayıtlı görüntülerle belirlenen metriğe göre karşılaştırılıp, en yüksek değere sahip 10 adet görüntü sonucu alınmıştır. Bu sonuçlara göre karar aşağıdaki işlem adımlarına göre yapılmıştır (Şekil 4.10):

1) Tüm karşılaştırma sonuçları belirlenen metriğe göre en iyi sonuçtan en kötü sonuca doğru sıralanmıştır.

2) En iyi sonuç veren 10 görüntü içinde doğrulanması gereken sınıfa ait 2 veya daha fazla sonuç varsa, başarılı kabul edilmiştir. Değilse 3. adıma geçilmiştir.


3) En iyi sonuç veren 10 görüntü arasında sadece bir görüntü varsa ve bu görüntü en iyi skora sahipse sonuç doğru kabul edilmiştir. Değilse 4. adıma geçilmiştir.

4) Tüm görüntüler için sınıfların (kişilerin [1, 108] id no) ağırlıklı ortalaması alınmış ve en iyiden en kötüye doğru sıralanmıştır. Birinci sıradaki değer doğrulanacak sınıfa aitse doğru kabul edilmiştir. Aksi durumda sonuç hatalı kabul edilmiştir.

Tez kapsamında karşılaştırma işlemi 2 farklı şekilde yapılmıştır:

1) Sadece K-TDA uygulanıp, elde edilen gri seviye görüntüler için [0-255] arası piksel değerleri kullanılarak karşılaştırma yapılmıştır.


2) K-TDA ve ardından HE uygulanıp, şablon çıkarılmış siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak karşılaştırma yapılmıştır.



Şekil 4.10. Karşılaştırma için görüntü doğrulama aşamaları

5. DENEYSEL SONUÇLAR

CASIA-Iris V1 veritabanında 108 kişiye ait toplam 756 iris görüntüsü bulunmaktadır. Tez kapsamında öncelikle tüm görüntülerden iris alanının çıkarılması işlemi yapılmıştır. Ancak bazı görüntülerde; iris alanındaki sorunlar nedeniyle alınan iris kesit alanları K-TDA ile işleme alındığında, iris tanıma için kullanılabilir sonuçlar üretilenmemiştir. Bu nedenle sonuç alınamayan 20 adet görüntü veritabanından çıkarılmıştır. Şekil 5.1’de veritabanında bulunan ancak K-TDA uygulandığında iris tanıma için sonuç üretilenmemiş görüntülerden örnekler verilmiştir.



Şekil 5.1. Segmentasyonu başarısız olan bazı görüntüler. (a) göz kapağının engellemesi, (b) iris içinde siyaha yakın bölgeler bulunması, (c) iris dokusunda siyah nokta bulunması, (d) gözbebeği ile birleşen kirpik bulunması

Tez kapsamında görüntülerin karşılaştırılması için Yapısal Benzerlik İndeksi (YBİ), Hamming Uzaklığı (HU), Öklid Uzaklığı (ÖU) ve Ortalama Karesel Hata

(OKH) metrikleri kullanılmıştır. Bu metriklerden YBİ için yüksek değer en iyi sonucu verirken, diğer metriklerde en düşük değer en iyi sonuç olarak alınmaktadır. Karşılaştırma işlemi Şekil 4.9'daki işlem sırasına göre yapılmıştır. Buna göre, ilk karşılaştırma adımında, karşılaştırma sonuçlarına göre en iyi değeri veren 10 sonuç görüntüsünde 2 veya daha fazla görüntü, karşılaştırma yapılan görüntü ile aynı sınıfta ise sonuç başarılı kabul edilmiştir. Aksi durumda, en iyi 10 sonuç görüntüsünde aynı sınıftan 2'den az görüntü olması durumunda, karşılaştırma yapılan görüntü ile aynı sınıfta olan 1 adet görüntü varsa ve bu görüntü en iyi sonucu üretmişse, sistem sonucu başarı olarak alınmıştır. Bu aşamada da sonuç alınamazsa, en son olarak 10 sonuç görüntüsünde bulunan tüm sınıflar için ağırlıklı ortalama başarı değeri hesaplanmış ve elde edilen değerlere göre karşılaştırma yapılmıştır.

Karşılaştırma işlemlerinde K-TDA için sözlük atom sayısı, hata hedefi, blok boyutu ve iterasyon sayısı olarak 4 farklı parametre değeri, farklı değerlerde kullanılarak sonuçlar incelenmiştir. Tez kapsamında kullanılan parametreler ve parametrelere ait değer aralıkları Çizelge 5.1'de verilmiştir. Hata hedefinin sıfıra yakınsaması iterasyon sayısına bağlı olarak sağlanabilir, fakat tam olarak 0 olmayacağı ve her görüntü için farklı sayıda iterasyon gerektireceği için, 0 değeri tercih edilmemiştir.

Çizelge 5.1. K-TDA sonuçlarının karşılaştırılması için kullanılan parametreler ve değer aralıkları

Sözlük atom sayısı	Hata hedefi	Blok boyutu	İterasyon sayısı
16-32-64-128-256	1-2-4	4-6-8	1-5-10

Tez kapsamında yapılan ilk karşılaştırma işleminde görüntülere K-TDA uygulanıp, elde edilen gri seviye görüntüler için 0-255 arası piksel değerleri kullanılarak karşılaştırma yapılmıştır. Bu işlemde Çizelge 5.2'deki sonuçlardan görülebileceği üzere YBİ metriği ile yapılan işlemlerde, yalnız ilk karşılaştırma adımı çalıştırıldığında sistemde sonuca ulaşılmasında %90 üstünde başarı elde edilmiştir. Ek olarak, tüm karşılaştırma adımları sırasıyla işlenip, sistem sonuçları değerlendirildiğinde ise başarı %95 üzerinde çıkmıştır.

Tez kapsamında yapılan diğer karşılaştırma işleminde ise görüntülere K-TDA ve ardından histogram eşitleme (HE) uygulanıp, şablon çıkarılan siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak karşılaştırma yapılmıştır. Şablon çıkarma aşamasında elde edilen maksimum ve minimum sonuçlar ise Yapısal Benzerlik İndeksi

(YBİ), Hamming Uzaklığı (HU), Öklid Uzaklığı (ÖU) ve Ortalama Karesel Hata (OKH) değerlerine göre Çizelge 5.3’de verilmiştir.

Çizelge 5.2. Sadece K-TDA uygulanıp, elde edilen gri seviye görüntüler için [0-255] arası piksel değerleri kullanılarak YBİ ile yapılan karşılaştırma sonuçlarının atom sayılarına göre minimum ve maksimum değerleri (Tablonun tamamı için EK-1’e bakılabilir)

Değer	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
Max. Değerler	256	1	8	10	93.08	97.09
	128	1	8	1	92.94	97.09
	64	1	8	5	92.94	96.95
	32	1	8	10	93.36	97.51
	16	1	6	5	93.36	97.37
Min. Değerler	256	4	8	5	91	95.02
	128	4	8	5	91.14	95.15
	64	4	8	10	90.87	95.15
	32	4	6	1	91.7	95.57
	16	2	8	10	79.25	88.52

Çizelge 5.3. K-TDA ve ardından HE uygulanıp, şablon çıkarılmış siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak karşılaştırma sonuçlarının yöntemine göre minimum ve maksimum değerleri (Tabloların tamamı için EK-2, EK-3, EK-4 ve EK-5’e bakılabilir)

Değer	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Karşılaştırma Metriği	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
Max. Değerler	32	2	6	10	OKH	80.22	99.72
	32	4	6	5	ÖU	12.17	99.86
	32	2	6	10	HU	51.59	99.44
	64	4	8	5	YBİ	90.31	93.22
Min. Değerler	16	2	8	1	OKH	46.95	98.89
	16	1	8	10	ÖU	1.24	99.03
	16	1	8	10	HU	17.01	99.03
	16	2	8	10	YBİ	61.96	68.87

6. SONUÇLAR VE ÖNERİLER

6.1. Sonuçlar

Tez kapsamında geliştirilen uygulamalarda sözlük öğrenme ile görüntü ayırt edici özelliklerinin vurgulanması ile iris tanıma yapılan bir sistem önerilmiştir. Tez kapsamında karşılaştırma metriği olarak Yapısal Benzerlik İndeksi (YBİ), Ortalama Karesel Hata (OKH), Hamming Uzaklığı (HU) ve Öklid Uzaklığı (ÖU) kullanılmıştır.

Tezde sunulan iris tanıma sistemi segmentasyon zamanı ve segmentasyon hataları noktasında iyi sonuçlar üretirken, başarımları ve diğer kriterler açısından rekabetçi bir görüntü sunmaktadır. Tezde kullanılan Hough Dairesel Dönüşüm yöntemi, segmentasyon hataları bakımından literatürdeki yöntemler arasında hata oranının azlığı açısından üst sıralarda yer almaktadır. Tezde kullanılan Hough Dairesel Dönüşümü yöntemi tek çekirdek üzerinde 78 ms sürede çalışmakta ve masaüstü işlemciler arasında üst sıralarda yer alarak, FPGA tabanlı ve mobil işlemcilerle rekabetçi gözükmektedir. K-TDA ile iris görüntüsünün ayırt edici özelliklerinin çıkarılarak yapılan çalışma sonuçları literatürdeki yaklaşımlarla rekabetçi bir görüntü ortaya koymaktadır.

YBİ metriği kullanılarak yapılan karşılaştırma sonuçları literatürdeki diğer sonuçlarla rekabetçi gözükmeyle beraber, soft computing metodlarına göre daha az zaman gerektirmektedir. Bununla beraber iris şablonu kullanılarak yapılan çalışmalarda %99.86 başarımları (Öklid uzaklık metriği ile) sağlayarak, önerilen sistem oldukça iyi bir sonuç ortaya koymuştur. Ayrıca sonuçlar, K-TDA metodunun iris tanımada kullanımının sınırlı bir parametre uzayına bağlı olmadığını göstermiştir.

Çizelge 5.1 için, tüm karşılaştırma adımları çalıştırıldığında, ortalama başarımın (EK-1'deki) %96.38 olarak gerçekleştiği görülürken, sadece ilk karşılaştırma adımına göre başarımın ortalama %92.22 olduğu görülmektedir.

Çizelge 5.2'ye göre, iris şablonu üretilmiş sonuçlar içinde, OKH kullanan metriğin ortalama başarımları %99.46 olmuştur. Öklid uzaklığı metriğini kullanan yöntemin ortalama başarısı ise %99.38 olarak gerçekleşmiştir. YBİ metriğinin ortalama başarısı ise %91.33 olmuştur. Hamming uzaklığı kullanan metod ise ortalama %99.24 başarı sağlamıştır. Tüm karşılaştırma sonuçları için EK-2, EK-3, EK-4, EK-5'e bakılabilir.

Tez kapsamında yapılan tüm çalışma sonuçları incelendiğinde, toplam sözlük atom sayısının artmasının ve hata hedefinin düşürülmesinin sistem başarımlarını artırdığı

gözlenmiştir. İterasyon sayısının artırılmasının da sistem üzerindeki başarıyı artırıcı etkisi tespit edilmiştir.

Çizelge 6.1'den görüleceği üzere tez kapsamında elde edilen sonuçlar özellikle iris tanıma alanında literatürde en önce gelen Daugman (Daugman, 2004) yöntemi ile karşılaştırılmıştır. Karşılaştırılan Daugman yöntemi tez kapsamında YBİ karşılaştırma ölçütü kullanılarak test edilmiştir. Daugman yöntemi, YBİ metriği ile %89.90 başarıya ulaşmışken, K-TDA yöntemi şablonsuz olarak %99.3 başarıya ulaşmıştır.

Biyometrik tanıma sistemlerinde başarının yanında HKO/HRO (Hatalı Kabul Oranı/Hatalı Red Oranı) (FAR/FRR – False Acceptance Rate/False Reject Rate) oranları da önemlidir. Tez kapsamında yapılan çalışmalarda K-TDA için HKO/HRO değerleri 0.00/0.0014 olmuştur. Bu değerler literatür ile rekabetçi gözükmemektedir.

K-TDA kullanan yöntem görüntü üzerinde normalizasyon kaynaklı hatalar ve tekrar eden pikselleri, görüntü üzerinden öğrendiği sözlük ile elemine ederek ayrıntıları daha iyi vurgulanmış bir görüntü elde etmeye çalışmıştır.

6.2. Öneriler

Segmentasyon, normalizasyon, restorasyon ve gürültü giderme işlemleri için herhangi bir paralelleştirme uygulanmamış olup, açıklanan süre ve değerler paralelleştirme ve yüksek hesaplama gücü ile geliştirilmeye açıktır.

Segmentasyon aşamasındaki hataların giderimi için literatürdeki farklı metodlar denenebilir, bununla beraber halihazırda segmentasyon yapılmış görüntüler için daha doğru segmentasyon sağlanabilecektir.

Tez çalışmasında kullanılan sözlük öğrenme yöntemi olan K-TDA yaklaşımı dışında kalan diğer yöntemler de araştırılabilir ve sözlük öğrenmenin seyrek gösterim gücü iris tanıma alanında özellikle özellik çıkarma ve özellik vektörü oluşturma gibi alanlarda daha fazla kullanılabilir.

Çizelge 6.1. Literatürdeki metotlar ve başarı değerleri

Çalışma	Veritabanı	Özellik Çıkarma Yöntemi	Sınıflandırıcı	Başarı
(Bharadwaj ve ark., 2021)	CASIA V3	4 seviye Haar Dalgacıkları	HU	Başarı: 95.40, HKO: 3.81, HRO: 5.39
(Jayanthi ve ark., 2021)	CASIA-Iris-Thousand	Özellik Piramit Ağı + RCNN	ResNet-50-C4	Başarı 99.14
(Lavanya ve Kavitha, 2021)	CASIA-Iris-V3 Interval	Gabor Dalgacık Dönüşümü + Gabor wavelet transform + Yerel Faz Dönüşümü (LPQ)	Tom Arama Optimizasyonu (ASO) + İleri beslemeli karşı propogasyona sahip YSA	Başarı: 99.71
(Xiong ve ark., 2021)	CASIA IRIS Distance	2 Boyutlu Log-Gabor dönüşümü ve Dalgacık Dönüşümü	Değiştirilmiş kaotik ikili parçacık sürü optimizasyonu (MCBPSO) + Çekirdek Aşırı Öğneme Makinesi (KELM)	Başarı: 99.78 HKO: 0.003
(Asaker ve ark., 2021)	CASIA-IrisV3	Log-Gabor Filtresi	Hamming Uzaklığı	Başarı: 99.57 EHO: 0.0043
(Soliman ve ark., 2020)	CASIA-IrisV3-Interval	Log-Gabor filtresi ve Tarak Filtresi	Hamming Uzaklığı + Alıcı Operatör Karakteristikleri (ROC)	Başarı 99.75, EHO: 0.36
(Adamović ve ark., 2020)	CASIA-Iris V4	Stilometrik Özelelik Çıkarımı	HU	Başarı: 99.98, HKO: 0
(Liu ve ark., 2020)	CASIA-iris-thousand	Kapsül Ağları	Kapsülün vektör çıkışı	Başarı: 81.4
(Chen ve ark., 2020)	CASIA-Thousand	Derin Konvülsiyonel YSA	Sıkı Merkez (T -Center) Skoru	Başarı: 98.75
(Dua ve ark., 2019)	CASIA IRIS V1	1 Boyutlu Gabor Filtresi	Radyal Temel Fonksiyonu YSA	Başarı 97
(Ahmadi ve ark., 2019)	CASIA-Iris V3	İki Boyutlu Gabor Çekirdekleri, Adım Filtreleri ve Polinom filtreleme	Radyal Temel Fonksiyonu YSA	Başarı: 99.99
(Vyas ve ark., 2019)	CASIA-v4-Interval	Dalgacık Dönüşümü ve Tam Frekans Spektrumu	Alıcı Operatör Karakteristikleri (ROC)	EHO: 0.1388
(Tobji ve ark., 2019)	CASIA-Iris-Thousand	Çok Boyutlu Konvülsiyonel YSA	Tam Konvülsiyonel Ağ (FCN)	Başarı: 95.63
(Zhao ve ark., 2019)	JluIrisV3.1	Derin özellikler	Konvülsiyonel kapsül ağları (Inceptionv3_5blo cks +DRDL)	Başarı: 99.37 EHO:0.039
(Rana ve ark., 2019)	CASIA-Iris V4	Ayrık Kosinüs Dönüşümü ve Birincil Bileşen Analizi	Destek Vektör Makineleri	HKO: 4 HRO: 5 Başarı: 95.4
Önerilen Yöntem (2021)	CASIA V1	K-TDA (görüntü zenginleştirme ile)	ÖU	Başarı: 99.86, HKO: 0.0 HRO: 0.0014
HKO: Hatalı Kabul Oranı (FAR – False Acceptance Rate), HRO: Hatalı Red Oranı (FRR – False Rejected Rate) EHO: Eşit Hata Oranı (EER – Equal Error Rate)				

6.3. Tartışma

Sonuçlarda kullanılan tüm değerler YBİ metriği için açıklanmış olup, Öklid Uzaklığı bazlı yöntem K-TDA uygulanmış resimlerde %99.86 başarı vermektedir.

Geleneksel olarak iris tanıma sistemlerinde Gabor filtreleri ve Hamming Uzaklığı metriği kullanılmaktadır. Gabor uygulanmış görüntülerde ise YBİ metriği kullanan yöntemin başarısı %70 civarında olmaktadır. Buradan Hamming Uzaklığının, Gabor filtreleri ile iyi sonuç verirken YBİ metriği için yeterli olmadığı gözükmemektedir.

Bununla beraber tezde kullanılan K-TDA ve karşılaştırma için kullanılan YBİ metriği iris tanıma sistemleri için özgün bir yaklaşımdır ve geliştirilmeye açıktır. Tez kapsamında önerilen yöntem, tanılama (identification) modunda, Hatalı Kabul Oranı (HKO) düşüklüğü (0.00) ve Hatalı Red Oranı (HRO) düşüklüğü (0.0014) ile literatürde oldukça iyi bir yer edinmekte, bununla beraber %99.86 başarı oranıyla da literatürde yapılan çalışmalarla rekabetçi bir görüntü sunmaktadır.

KAYNAKLAR

- Abdulsamad, N. E. A. ; E. J. A. T. ; Z. (2018). Improve image de-blurring. *International Conference on Innovative Trends in Computer Engineering (ITCE)*, 25–30.
- Adamović, S., Mišković, V., Maček, N., Milosavljević, M., Šarac, M., Saračević, M., & Gnjatović, M. (2020). An efficient novel approach for iris recognition based on stylometric features and machine learning techniques. *Future Generation Computer Systems*, 107, 144–157. <https://doi.org/https://doi.org/10.1016/j.future.2020.01.056>
- Adler, A., Emiya, V., Jafari, M. G., Elad, M., Gribonval, R., & Plumbley, M. D. (2012). Audio Inpainting. *IEEE Transactions on Audio, Speech, and Language Processing*, 20(3), 922–932. <https://doi.org/10.1109/TASL.2011.2168211>
- Aharon, M., Elad, M., & Bruckstein, A. (2006). K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation. *IEEE Transactions on Signal Processing*, 54(11), 4311–4322. <https://doi.org/10.1109/TSP.2006.881199>
- Ahmadi, N., Nilashi, M., Samad, S., Rashid, T. A., & Ahmadi, H. (2019). An intelligent method for iris recognition using supervised machine learning techniques. *Optics and Laser Technology*, 120(December 2018), 105701. <https://doi.org/10.1016/j.optlastec.2019.105701>
- Akhan, N. (2004). *Bilgisayar Destekli İris Tanıma* [Selçuk Üniversitesi]. <http://acikerisim.selcuk.edu.tr:8080/xmlui/handle/123456789/4787>
- Ali, H. S., Ismail, A. I., Farag, F. A., & El-Samie, F. E. A. (2016). Speeded up robust features for efficient iris recognition. *Signal, Image and Video Processing*, 10(8), 1385–1391. <https://doi.org/10.1007/s11760-016-0903-8>
- Aloudat, A., Michael, K., & Abbas, R. (2016). The Implications of Iris-Recognition Technologies: Will our eyes be our keys? *IEEE Consumer Electronics Magazine*, 5(3), 95–102. <https://doi.org/10.1109/MCE.2016.2556901>
- Alpaydin, E. (2014). *Introduction to Machine Learning*. MIT Press. <https://books.google.com.tr/books?id=7f5bBAAAQBAJ>
- Asaker, A. A., Elsharkawy, Z. F., Nassar, S., Ayad, N., Zahran, O., & Abd El-Samie, F. E. (2021). A novel cancellable Iris template generation based on salting approach. *Multimedia Tools and Applications*, 80(3), 3703–3727. <https://doi.org/10.1007/s11042-020-08663-6>
- Ashbourn, J. (2015). *Practical Biometrics: From Aspiration to Implementation* (1.). Springer, London. <https://doi.org/https://doi.org/10.1007/978-1-4471-6717-4>
- AZİZOĞLU, B. (2017). *SEYREKLİK VE SÖZLÜK ÖĞRENME YAKLAŞIMLARININ SINIFLANDIRMA VE YÜZ TANIMAYA UYGULANMASI* (Issue Haziran).
- Bae, K., Noh, S., & Kim, J. (2003). Iris Feature Extraction Using Independent Component Analysis. In J. Kittler & M. S. Nixon (Eds.), *Audio and Video-Based Biometric Person Authentication* (pp. 838–844). Springer Berlin Heidelberg.
- Bahrampour, S., Nasrabadi, N. M., Ray, A., & Jenkins, W. K. (2016). Multimodal task-driven dictionary learning for image classification. *IEEE Transactions on Image Processing*, 25(1), 24–38. <https://doi.org/10.1109/TIP.2015.2496275>
- Bakshi, S., Mehrotra, H., & Majhi, B. (2011). Real-Time Iris Segmentation Based on Image Morphology. *Proceedings of the 2011 International Conference on Communication, Computing & Security*, 335–338. <https://doi.org/10.1145/1947940.1948010>
- Balaji, S. R., & Karthikeyan, S. (2017). A survey on moving object tracking using image processing. *2017 11th International Conference on Intelligent Systems and Control (ISCO)*, 469–474. <https://doi.org/10.1109/ISCO.2017.7856037>
- Barthélemy, Q., Gouy-Pailler, C., Isaac, Y., Souloumiac, A., Larue, A., & Mars, J. I.

- (2013). Multivariate temporal dictionary learning for EEG. *Journal of Neuroscience Methods*, 215(1), 19–28. <https://doi.org/10.1016/j.jneumeth.2013.02.001>
- Belcher, C., & Du, Y. (2009). Region-based SIFT approach to iris recognition. *Optics and Lasers in Engineering*, 47(1), 139–147. <https://doi.org/10.1016/J.OPTLASENG.2008.07.004>
- Benalcazar, D. P., Perez, C. A., Bastias, D., & Bowyer, K. W. (2019). Iris Recognition: Comparing Visible-Light Lateral and Frontal Illumination to NIR Frontal Illumination. *{IEEE} Winter Conference on Applications of Computer Vision, {WACV} 2019, Waikoloa Village, HI, USA, January 7-11, 2019*, 867–876. <https://doi.org/10.1109/WACV.2019.00097>
- Bendale, A., Nigam, A., Prakash, S., & Gupta, P. (2012). Iris Segmentation Using Improved Hough Transform. In D.-S. Huang, P. Gupta, X. Zhang, & P. Premaratne (Eds.), *International Conference on Intelligent Computing - ICIC 2012 Emerging Intelligent Computing Technology and Applications* (pp. 408–415). Springer Berlin Heidelberg.
- Bertalmio, M., Sapiro, G., Caselles, V., & Ballester, C. (2000). Image Inpainting. *Proceedings of the 27th Annual Conference on Computer Graphics and Interactive Techniques*, 417–424. <https://doi.org/10.1145/344779.344972>
- Bharadwaj, S., Deepika, K., & Upadhyay, K. (2021). Improved biometric iris recognition using watershed transform. *Journal of Physics: Conference Series*, 1714(1). <https://doi.org/10.1088/1742-6596/1714/1/012035>
- Biglieri, E., & Yao, K. (1989). Some properties of singular value decomposition and their applications to digital signal processing. *Signal Processing*, 18(3), 277–289. [https://doi.org/10.1016/0165-1684\(89\)90039-X](https://doi.org/10.1016/0165-1684(89)90039-X)
- Boles, W. W., & Boashash, B. (1998). A Human Identification Technique Using Images of the Iris and Wavelet Transform. *IEEE Transactions on Signal Processing*, 46(4), 1185–1188. <https://doi.org/10.1109/78.668573>
- Böttcher, A., & Wenzel, D. (2008). The Frobenius norm and the commutator. *Linear Algebra and Its Applications*, 429(8–9), 1864–1885. <https://doi.org/10.1016/J.LAA.2008.05.020>
- Bowyer, K. W., Hollingsworth, K., & Flynn, P. J. (2008). Image understanding for iris biometrics: {A} survey. *Computer Vision and Image Understanding*, 110(2), 281–307. <https://doi.org/10.1016/j.cviu.2007.08.005>
- Brunet, D., Vrscay, E. R., & Wang, Z. (2012). On the Mathematical Properties of the Structural Similarity Index. *IEEE Transactions on Image Processing*, 21(4), 1488–1499. <https://doi.org/10.1109/TIP.2011.2173206>
- Bulut, S. (2011). *İris görüntülerinin analiziyle kimlik tanıma*.
- Caballero, J., Price, A. N., Rueckert, D., & Hajnal, J. V. (2014). Dictionary learning and time sparsity for dynamic MR data reconstruction. *IEEE Transactions on Medical Imaging*, 33(4), 979–994. <https://doi.org/10.1109/TMI.2014.2301271>
- Canny, J. (1986). A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6), 679–698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- Chen, Y., Wu, C., & Wang, Y. (2020). T-Center: A Novel Feature Extraction Approach towards Large-Scale Iris Recognition. *IEEE Access*, 8, 32365–32375. <https://doi.org/10.1109/ACCESS.2020.2973433>
- Cui, J., Wang, Y., Tan, T., Ma, L., & Sun, Z. (2004). A fast and robust iris localization method based on texture segmentation. In A. K. Jain & N. K. Ratha (Eds.), *Biometric Technology for Human Identification* (Vol. 5404, pp. 401–408). SPIE.

- <https://doi.org/10.1117/12.541921>
- Daugman, J. (1994). *Biometric personal identification system based on iris analysis*.
- Daugman, J. (2004). How Iris Recognition Works. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 21–30.
- Daugman, J. (2005). *Results from 200 billion iris cross-comparisons* (Issue UCAM-CL-TR-635). <https://www.cl.cam.ac.uk/techreports/UCAM-CL-TR-635.pdf>
- Daugman, J. (2007). New Methods in Iris Recognition. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS*, 37(5), 1167–1175.
- Daugman, J. G. (1993). High confidence visual recognition of persons by a test of statistical independence. *{IEEE} Transactions on Pattern Analysis and Machine Intelligence*, 15(11), 1148–1161. <https://doi.org/10.1109/34.244676>
- Davis, S., & Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 28(4), 357–366. <https://doi.org/10.1109/TASSP.1980.1163420>
- Deshpande, H., Maurel, P., & Barillot, C. (2015). Classification of multiple sclerosis lesions using adaptive dictionary learning. *Computerized Medical Imaging and Graphics*, 46, 2–10. <https://doi.org/10.1016/j.compmedimag.2015.05.003>
- Dorairaj, V., Schmid, N. A., & Fahmy, G. (2005). Performance evaluation of non-ideal iris based recognition system implementing global {ICA} encoding. *{IEEE} International Conference on Image Processing 2005*. <https://doi.org/10.1109/icip.2005.1530384>
- Dosselmann, R., & Yang, X. D. (2011). A comprehensive assessment of the structural similarity index. *Signal, Image and Video Processing*, 5(1), 81–91. <https://doi.org/10.1007/s11760-009-0144-1>
- Dua, M., Gupta, R., Khari, M., & Crespo, R. G. (2019). Biometric iris recognition using radial basis function neural network. *Soft Computing*, 23(22), 11801–11815. <https://doi.org/10.1007/s00500-018-03731-4>
- Dumitrescu, B., & Paul Irofti. (2018). *Dictionary Learning Algorithms and Applications*.
- Dumpala, S. H., & Alluri, K. N. R. K. (2017). *An Algorithm for Detection of Breath Sounds in Spontaneous Speech with Application to Speaker Recognition*. 98–108. https://doi.org/10.1007/978-3-319-66429-3_9
- Efron, B., Hastie, T., Johnstone, I., & Tibshirani, R. (2004). Least angle regression. *The Annals of Statistics*, 32(2), 407–499. <https://doi.org/10.1214/009053604000000067>
- Elharrouss, O., Almaadeed, N., Al-Maadeed, S., & Akbari, Y. (2016). Image Inpainting Approaches - A Review. *Proceedings - 6th International Advanced Computing Conference, IACC 2016*, 340–345. <https://doi.org/10.1109/IACC.2016.70>
- Ernawan, F., Abu, N., & Suryana, N. (2011). Spectrum analysis of speech recognition via discrete Tchebichef transform. *Proceedings of SPIE - The International Society for Optical Engineering*, 8285, 82856L-82856L. <https://doi.org/10.1117/12.913491>
- Eskandari, M., Toygar, Ö., & Demirel, H. (2014). Feature extractor selection for face–iris multimodal recognition. *Signal, Image and Video Processing*, 8(6), 1189–1198. <https://doi.org/10.1007/s11760-014-0659-y>
- Faundez-Zanuy, M. (2006). Biometric security technology. *IEEE Aerospace and Electronic Systems Magazine*, 21(6), 15–26. <https://doi.org/10.1109/MAES.2006.1662038>
- Fawzi, A., Davies, M., & Frossard, P. (2015). Dictionary Learning for Fast Classification Based on Soft-thresholding. *International Journal of Computer*

- Vision*, 114(2–3), 306–321. <https://doi.org/10.1007/s11263-014-0784-7>
- Flom, L., & Safir, A. (1987). *Iris recognition system*.
- Friedman, J., Hastie, T., Höfling, H., & Tibshirani, R. (2007). Pathwise coordinate optimization. *The Annals of Applied Statistics*, 1(2), 302–332. <https://doi.org/10.1214/07-aos131>
- Fu, W. J. (1998). Penalized Regressions: The Bridge versus the Lasso. *Journal of Computational and Graphical Statistics*, 7(3), 397–416. <https://doi.org/10.1080/10618600.1998.10474784>
- Gangeh, M. J. (2013). *Kernelized supervised dictionary learning*. <https://doi.org/10.1109/TSP.2013.2274276>
- Gangeh, M. J., Farahat, A. K., & Ghodsi, A. (2015). Supervised Dictionary Learning and Sparse Representation-A Review. *Elsevier*, 0–60.
- Garcia-Cardona, C., & Wohlberg, B. (2018). Convolutional Dictionary Learning: A Comparative Review and New Algorithms. *IEEE Transactions on Computational Imaging*, 4(3), 366–381. <https://doi.org/10.1109/tci.2018.2840334>
- Göksu Tüysüzoğlu. (2016). *SPARSE CODING BASED ENSEMBLE CLASSIFIERS COMBINED WITH ACTIVE LEARNING FRAMEWORK FOR DATA CLASSIFICATION*. İstanbul Teknik Üniversitesi.
- Gorodnichy, D. O. (2010). Multi-order analysis framework for comprehensive biometric performance evaluation. In B. V. K. V. Kumar, S. Prabhakar, & A. A. Ross (Eds.), *Biometric Technology for Human Identification VII* (Vol. 7667, pp. 152–163). SPIE. <https://doi.org/10.1117/12.849801>
- Gr, V., & Prasad, S. V. A. . (2017). ROBUST METHOD FOR THE CLASSIFICATION OF THE ARRHYTHMIA WITH DNN CLASSIFIER IN THE DIVERSE ECG SIGNAL. *International Journal of Computer Engineering & Technology (IJCET)*, 8(5), 107–119.
- Gürkan, G. (2005). *Gabor Filtreler Kullanarak Iris Tanıma* [İstanbul Üniversitesi]. http://www.ghbook.ir/index.php?name=فرهنگ و رسانه های نوین&option=com_dbook&task=readonline&book_id=13650&page=73&chkhask=ED9C9491B4&Itemid=218&lang=fa&tmpl=component
- Hanna, K. J., Burt, P. J., Peleg, S., Dixon, D. F., Mishra, D., Wixon, L. E., Mandlebaum, R., Coyle, P., & Herman, J. R. (2004). *Fully automated iris recognition system utilizing wide and narrow fields of view* (Patent No. US6714665B1).
- Haralick, R. M., & Shapiro, L. G. (1985). Image segmentation techniques. *Computer Vision, Graphics, and Image Processing*, 29(1), 100–132. [https://doi.org/10.1016/S0734-189X\(85\)90153-7](https://doi.org/10.1016/S0734-189X(85)90153-7)
- Hashim, N., ZainalAbidin, Z., Shibghatullah, A., AbalAbas, Z., & Yusof, N. (2016). A New Model of Crypt Edge Detection Using PSO and Bi-cubic Interpolation for Iris Recognition. In H. A. Sulaiman, M. A. Othman, M. F. I. Othman, Y. A. Rahim, & N. C. Pee (Eds.), *Advanced Computer and Communication Engineering Technology* (pp. 659–669). Springer International Publishing.
- Henaff, M., Jarrett, K., Kavukcuoglu, K., & LeCun, Y. (2011). Unsupervised learning of sparse features for scalable audio classification. *International Conference on Music Information Retrieval, Ismir*, 681–686. <http://www.ismir2011.ismir.net/papers/PS6-5.pdf>
- Horé, A., & Ziou, D. (2010). Image quality metrics: PSNR vs. SSIM. *Proceedings - International Conference on Pattern Recognition*, 2366–2369. <https://doi.org/10.1109/ICPR.2010.579>
- Huang, X., Baker, J., & Reddy, R. (2014). A Historical Perspective of Speech

- Recognition. *Communications of the ACM*, 57, 94–103. <https://doi.org/10.1145/2500887>
- Huang, Y., Luo, S., & Chen, E. (2002). An Efficient Iris Recognition System. *1st Int'l. Conf. Machine Learning and Cybernetics, China*.
- Jain, A. K., Ross, A., & Pankanti, S. (2006). Biometrics: A tool for information security. *IEEE Transactions on Information Forensics and Security*, 1(2), 125–143. <https://doi.org/10.1109/TIFS.2006.873653>
- Jain, A., Zappella, L., & McClure, P. (2012). *Visual Dictionary Learning for Joint Object Categorization and Segmentation*. 718–731.
- Jayanthi, J., Lydia, E. L., Krishnaraj, N., Jayasankar, T., Babu, R. L., & Suji, R. A. (2021). An effective deep learning features based integrated framework for iris detection and recognition. *Journal of Ambient Intelligence and Humanized Computing*, 12(3), 3271–3281. <https://doi.org/10.1007/s12652-020-02172-y>
- Jeong, D. S., Hwang, J. W., Kang, B. J., Park, K. R., Won, C. S., Park, D.-K., & Kim, J. (2010). A new iris segmentation method for non-ideal iris images. *Image and Vision Computing*, 28(2), 254–260. <https://doi.org/10.1016/J.IMAVIS.2009.04.001>
- Jung, A., Eldar, Y. C., & Görtz, N. (2016). On the minimax risk of dictionary learning. *IEEE Transactions on Information Theory*, 62(3), 1501–1515. <https://doi.org/10.1109/TIT.2016.2517006>
- Junjun, J., Ruimin, H., Zhongyuan, W., & Zhen, H. (2014). Face Super-Resolution via Multilayer Locality-Constrained Iterative Neighbor Embedding and Intermediate Dictionary Learning. *Ieee Transactions on Image Processing*, 23(10), 4220–4231. <https://doi.org/10.1109/tip.2014.2347201>
- Kang, B. (2007). A Review on Image & Video Processing. *International Journal of Multimedia and Ubiquitous Engineering*, 2.
- Kang, B. J., & Park, K. R. (2007). Real-Time Image Restoration for Iris Recognition Systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 37(6), 1555–1566. <https://doi.org/10.1109/TSMCB.2007.907042>
- Kangjoo Lee, Sungho Tak, & Jong Chul Ye. (2010). A Data-Driven Sparse GLM for fMRI Analysis Using Sparse Dictionary Learning With MDL Criterion. *IEEE Transactions on Medical Imaging*, 30(5), 1076–1089. <https://doi.org/10.1109/tmi.2010.2097275>
- Kaur, P., Krishan, K., Sharma, S. K., & Kanchan, T. (2020). Facial-recognition algorithms: A literature review. *Medicine, Science and the Law*, 60(2), 131–139. <https://doi.org/10.1177/0025802419893168>
- Kaur, S., & Singh, N. (2014). Image Denoising Techniques: A Review. *International Journal of Innovative Research in Computer and Communication Engineering*, 2(6), 4578–4583. www.ijrcce.com
- Koh, J., Govindaraju, V., & Chaudhary, V. (2010). A Robust Iris Localization Method Using an Active Contour Model and Hough Transform. *2010 20th International Conference on Pattern Recognition*, 2852–2856. <https://doi.org/10.1109/ICPR.2010.699>
- Kong, W. K., & Zhang, D. (2001). Accurate iris segmentation based on novel reflection and eyelash detection model. *Proceedings of 2001 International Symposium on Intelligent Multimedia, Video and Speech Processing*. <https://doi.org/10.1109/isimp.2001.925384>
- Kumar, D. R. S., Raja, K. B., Nuthan, N., Sindhuja, B., Supriya, P., Chhotaray, R. K., & Pattnaik, S. (2011). Iris Recognition Based on DWT and PCA. *2011 International Conference on Computational Intelligence and Communication Networks*, 489–493. <https://doi.org/10.1109/CICN.2011.102>

- Kuruvilla, J., Sukumaran D., Sankar, A., Joy, S. P. (2016). A review on image processing and image segmentation. *International Conference on Data Mining and Advanced Computing*, 198–203.
- Latifa, G., Jazouli, M., Es-Sbai, N., Majda, A., & ZARGHILI, A. (2017). *Comparison between Euclidean and Manhattan distance measure for facial expressions classification*. 1–4. <https://doi.org/10.1109/WITS.2017.7934618>
- Lavanya, M., & Kavitha, V. (2021). A hybrid classical techniques and optimal decision model for iris recognition under variable image quality conditions. *Journal of Ambient Intelligence and Humanized Computing*, 0123456789. <https://doi.org/10.1007/s12652-020-02691-8>
- Li, Shutao, Yin, H., & Fang, L. (2012). Group-sparse representation with dictionary learning for medical image denoising and fusion. *IEEE Transactions on Biomedical Engineering*, 59(12), 3450–3459. <https://doi.org/10.1109/TBME.2012.2217493>
- Li, Si, Cao, Q., Chen, Y., Hu, Y., Luo, L., & Toumoulin, C. (2014). Dictionary learning based sinogram inpainting for CT sparse reconstruction. *Optik*, 125(12), 2862–2867. <https://doi.org/10.1016/J.IJLEO.2014.01.003>
- Lim, S., Lee, K., Byeon, O., & Kim, T. (2001). Efficient iris recognition through improvement of feature vector and classifier. *ETRI Journal*, 23(2), 61–70. <https://doi.org/10.4218/etrij.01.0101.0203>
- Lin, T.-H., & Tang, P. T. P. (2018). *Dictionary Learning by Dynamical Neural Networks*. <http://arxiv.org/abs/1805.08952>
- Liu, J., Sun, Z., & Tan, T. (2014). Distance metric learning for recognizing low-resolution iris images. *Neurocomputing*, 144, 484–492. <https://doi.org/10.1016/J.NEUCOM.2014.05.016>
- Liu, M., Zhou, Z., Shang, P., & Xu, D. (2020). Fuzzified Image Enhancement for Deep Learning in Iris Recognition. *IEEE Transactions on Fuzzy Systems*, 28(1), 92–99. <https://doi.org/10.1109/TFUZZ.2019.2912576>
- Liu, N., Li, H., Zhang, M., Jing Liu, Sun, Z., & Tan, T. (2016). Accurate iris segmentation in non-cooperative environments using fully convolutional networks. *2016 International Conference on Biometrics (ICB)*, 1–8. <https://doi.org/10.1109/ICB.2016.7550055>
- Liu, W., Song, C., & Wang, Y. (2012). Facial expression recognition based on discriminative dictionary learning. *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, 1839–1842.
- Lu, J., Wang, G., Deng, W., & Moulin, P. (2014). Simultaneous Feature and Dictionary Learning for Image Set Based Face Recognition. *Computer Vision ECCV 2014*, 265–280.
- M. Alrifaaee, M., M. Abdallah, M., & G. Al Okush, B. (2017). A Short Survey of IRIS Images Databases. *The International Journal of Multimedia & Its Applications*, 9(2), 01–14. <https://doi.org/10.5121/ijma.2017.9201>
- Magdics, M., Sauvaget, C., García Hernandez, R., & Sbert, M. (2013). Post-Processing NPR Effects for Video Games. *Conference: 12th ACM International Conference on Virtual Reality Continuum and Its Applications in Industry (VRCAI 2013)*. <https://doi.org/10.1145/2534329.2534348>
- Mailhe, B., Gribonval, R., Bimbot, F., Lemay, M., Vandergheynst, P., & Vesin, J.-M. (2009). Dictionary learning for the sparse modelling of atrial fibrillation in ECG signals. 465–468. <https://doi.org/10.1109/icassp.2009.4959621>
- Mairal, J., Bach, F., Ponce, J., & Sapiro, G. (2009). Online dictionary learning for sparse coding. *Proceedings of the 26th International Conference On Machine*

- Learning, ICML 2009*, 382, 87. <https://doi.org/10.1145/1553374.1553463>
- Mairal, J., Bach, F., Ponce, J., Sapiro, G., & Zisserman, A. (2008). *Supervised Dictionary Learning*. September. <http://arxiv.org/abs/0809.3083>
- Mairal, J., Bach, F., Project-team, I. W., & Sapiro, G. (2010). *2010 Julien Mairal Online learning for matrix factorization and sparse coding*. PDF. 11, 19–60.
- Mairal, J., Bach, F., Zisserman, A., & Sapiro, G. (2008). Supervised Dictionary Learning. *Proc. Neural Inf. Process. Syst.*, 1033–1040.
- Majekodunmi, T. O., & Idachaba, F. E. (2011). A review of the fingerprint, speaker recognition, face recognition and iris recognition based biometric identification technologies. *Proceedings of the World Congress on Engineering 2011, WCE 2011*, 2, 1681–1687.
- Mallat, S. G., & Zhifeng Zhang. (1993). Matching pursuits with time-frequency dictionaries. *IEEE Transactions on Signal Processing*, 41(12), 3397–3415. <https://doi.org/10.1109/78.258082>
- Mani, A., & Nadeski, M. (2015). *Processing solutions for biometric systems*. 11.
- Mat Raffei, A. F., Asmuni, H., Hassan, R., & Othman, R. M. (2013). Feature extraction for different distances of visible reflection iris using multiscale sparse representation of local Radon transform. *Pattern Recognition*, 46(10), 2622–2633. <https://doi.org/10.1016/J.PATCOG.2013.03.009>
- Matey, J. R., Naroditsky, O., Hanna, K., Kolczynski, R., LoIacono, D. J., Mangru, S., Tinker, M., Zappia, T. M., & Zhao, W. Y. (2006). Iris on the Move: Acquisition of Images for Iris Recognition in Less Constrained Environments. *Proceedings of the IEEE*, 94(11), 1936–1947. <https://doi.org/10.1109/JPROC.2006.884091>
- Mehrotra, H., Sa, P. K., & Majhi, B. (2013). Fast segmentation and adaptive SURF descriptor for iris recognition. *Mathematical and Computer Modelling*, 58(1–2), 132–146. <https://doi.org/10.1016/J.MCM.2012.06.034>
- Mery, D., & Bowyer, K. (2015). Automatic facial attribute analysis via adaptive sparse representation of random patches. *Pattern Recognition Letters*, 68, 260–269. <https://doi.org/https://doi.org/10.1016/j.patrec.2015.05.005>
- Minaee, S., Abdolrashidiy, A., & Wang, Y. (2016). An experimental study of deep convolutional features for iris recognition. *2016 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*, 1–6. <https://doi.org/10.1109/SPMB.2016.7846859>
- Misztal, K., Spurek, P., Saeed, E., Saeed, K., & Tabor, J. (2015). Cross entropy clustering approach to iris segmentation for biometrics purpose. *Schedae Informaticae*, 24, 31–40. <https://doi.org/10.4467/20838476SI.15.003.3025>
- Monro, D. M., Rakshit, S., & Zhang, D. (2007). DCT-Based Iris Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(4), 586–595. <https://doi.org/10.1109/tpami.2007.1002>
- Muralidharan, R., & Chandrasekar, C. (2014). *Edge detection using the Canny 's edge detector with user defined filter to obtain good feature for Object Recognition*. August.
- Ng, R Y F, Tay, Y. H., & Mok, K. M. (2008). An effective segmentation method for iris recognition system. *5th International Conference on Visual Information Engineering ({VIE} 2008)*. <https://doi.org/10.1049/cp:20080375>
- Ng, Richard Yew Fatt, Tay, Y. H., & Mok, K. M. (2008). A review of iris recognition algorithms. *2008 International Symposium on Information Technology*. <https://doi.org/10.1109/itsim.2008.4631656>
- Nguyen, K., Fookes, C., Ross, A., & Sridharan, S. (2018). Iris Recognition With Off-the-Shelf CNN Features: A Deep Learning Perspective. *IEEE Access*, 6, 18848–

18855. <https://doi.org/10.1109/ACCESS.2017.2784352>
- Osborne, M. R., Presnell, B., & Turlach, B. A. (2000). A new approach to variable selection in least squares problems. *IMA Journal of Numerical Analysis*, 20(3), 389–403. <https://doi.org/10.1093/imanum/20.3.389>
- Pan Lili, & Xie Mei. (2005). The algorithm of iris image preprocessing. *Fourth IEEE Workshop on Automatic Identification Advanced Technologies (AutoID'05)*, 134–138. <https://doi.org/10.1109/AUTOID.2005.47>
- Pankanti, S., Prabhakar, S., & Jain, A. K. (2002). On the individuality of fingerprints. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(8), 1010–1025. <https://doi.org/10.1109/TPAMI.2002.1023799>
- Paquette, E. (1999). *Computer Graphics and Image Processing as an Introductory Course How Computer Graphics is Presented Computer Graphics and Image Processing*.
<https://pdfs.semanticscholar.org/3e2a/a834274891c3f9dac85e61718745d16a9cd7.pdf>
- Pham, D., & Venkatesh, S. (2008). Joint learning and dictionary construction for pattern recognition. *2008 IEEE Conference on Computer Vision and Pattern Recognition*, 1–8. <https://doi.org/10.1109/CVPR.2008.4587408>
- Proença, H., & Alexandre, L. A. (2006). Iris segmentation methodology for non-cooperative recognition. *IEEE Proceedings - Vision, Image, and Signal Processing*, 153(2), 199. <https://doi.org/10.1049/ip-vis:20050213>
- Proença, H. (2010). Iris Recognition: On the Segmentation of Degraded Images Acquired in the Visible Wavelength. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(8), 1502–1516. <https://doi.org/10.1109/TPAMI.2009.140>
- Puhan, N. B., Sudha, N., & Sivaraman Kaushalram, A. (2011). Efficient segmentation technique for noisy frontal view iris images using Fourier spectral density. *Signal, Image and Video Processing*, 5(1), 105–119. <https://doi.org/10.1007/s11760-009-0146-z>
- Pundlik, S., Woodard, D., & Birchfield, S. (2010). Iris segmentation in non-ideal images using graph cuts. *Image and Vision Computing*, 28(12), 1671–1681. <https://doi.org/10.1016/J.IMAVIS.2010.05.004>
- Python Programming Language Web Page*. (2021). <https://www.python.org/>
- Qiu, X., Sun, Z., & Tan, T. (2007). Coarse Iris Classification by Learned Visual Dictionary. In S.-W. Lee & S. Z. Li (Eds.), *Advances in Biometrics* (pp. 770–779). Springer Berlin Heidelberg.
- Raja, H., & Bajwa, W. U. (2016). Cloud K-SVD: A collaborative dictionary learning algorithm for big, distributed data. *IEEE Transactions on Signal Processing*, 64(1), 173–188. <https://doi.org/10.1109/TSP.2015.2472372>
- Rana, H. K., Azam, M. S., Akhtar, M. R., Quinn, J. M. W., & Moni, M. A. (2019). A fast iris recognition system through optimum feature extraction. *PeerJ Computer Science*, 2019(4), 1–13. <https://doi.org/10.7717/peerj-cs.184>
- Rangayyan, R. M. (2000). Introduction to Enhancement. *Handbook of Medical Imaging*, 1–2. <https://doi.org/10.1016/B978-012077790-7/50003-5>
- Rashid, R. A., Mahalin, N. H., Sarijari, M. A., & Abdul Aziz, A. A. (2008). Security system using biometric technology: Design and implementation of Voice Recognition System (VRS). *2008 International Conference on Computer and Communication Engineering*, 898–902. <https://doi.org/10.1109/ICCCE.2008.4580735>
- Rioul, O., & Magossi, J. (2014). On Shannon's Formula and Hartley's Rule: Beyond the Mathematical Coincidence. *Entropy*, 16, 4892–4910.

- <https://doi.org/10.3390/e16094892>
- Roy, K., & Bhattacharya, P. (2008). Improving Features Subset Selection Using Genetic Algorithms for Iris Recognition. In L. Prevost, S. Marinai, & F. Schwenker (Eds.), *Artificial Neural Networks in Pattern Recognition* (pp. 292–304). Springer Berlin Heidelberg.
- Roy, K., Bhattacharya, P., & Suen, C. Y. (2011). Towards nonideal iris recognition based on level set method, genetic algorithms and adaptive asymmetrical SVMs. *Engineering Applications of Artificial Intelligence*, 24(3), 458–475. <https://doi.org/10.1016/J.ENGAPPAL.2010.06.014>
- Rubinstein, R., Faktor, T., & Elad, M. (2012). *K-SVD DICTIONARY-LEARNING FOR THE ANALYSIS SPARSE MODEL* Ron Rubinstein , Tomer Faktor and Michael Elad Departments of Computer Science and Electrical Engineering Technion – Israel Institute of Technology , Haifa 32000 , Israel { ronrubin @ cs , tomerfa @. 5405–5408.
- Rubinstein, R., Zibulevsky, M., & Elad, M. (2010). Double sparsity: Learning sparse dictionaries for sparse signal approximation. *IEEE Transactions on Signal Processing*, 58(3 PART 2), 1553–1564. <https://doi.org/10.1109/TSP.2009.2036477>
- Sahmoud, S. A., & Abuhaiba, I. S. (2013). Efficient iris segmentation method in unconstrained environments. *Pattern Recognition*, 46(12), 3174–3185. <https://doi.org/10.1016/J.PATCOG.2013.06.004>
- Sahu, B., Kumar Sa, P., Bakshi, S., & Sangaiah, A. K. (2018). Reducing dense local feature key-points for faster iris recognition. *Computers & Electrical Engineering*, 70, 939–949. <https://doi.org/10.1016/J.COMPELECENG.2017.12.048>
- Sanchez-Avila, C., & Sanchez-Reillo, R. (2005). Two different approaches for iris recognition using Gabor filters and multiscale zero-crossing representation. *Pattern Recognition*, 38(2), 231–240. <https://doi.org/10.1016/J.PATCOG.2004.07.004>
- Sathish, G. (2012). Multi-algorithmic IRIS Recognition. *International Journal of Computer Applications*, 38(11), 13–21. <https://pdfs.semanticscholar.org/af34/e109811eea3d5b12d9ac374cad3c4ec7209.pdf>
- Savant, S. (2014). a Review of Edge Detection Techniques for Image Segmentation. (*IJCSIT*) *International Journal of Computer Science and Information Technologies*, 5(4), 5898–5900. https://www.researchgate.net/publication/291975278_A_Review_on_Edge_Detection_Techniques_for_Image_Segmentation
- Sayeed, S., Nasir, I., & Ong, T. S. (2016). An Efficient Multimodal Biometric Authentication Integrating Fingerprint and Face Features. *American Journal of Applied Sciences*, 13, 1221–1227. <https://doi.org/10.3844/ajassp.2016.1221.1227>
- Seshadri, & Penchalaiah. (2011). Method for reducing of noise by improving Signal-to-Noise-Ratio in wireless LAN. *International Journal of Network Security & Its Applications*, 3(5), 115–120. <https://doi.org/10.5121/ijnsa.2011.3509>
- Shahin, M. (2016). *İris tanıma için görünür ışık ve yakın kızıl ötesi görüntülerinden öznelilik çıkarma ve birleştirme*. Dokuz Eylül Üniversitesi.
- Shamsi, M., & Rasouli, A. (2011). An Innovative Trapezium Normalization for Iris Recognition Systems. *2011 International Conference on Computer and Software Modeling*, 14, 118–122. <http://www.ipcsit.com/vol14/22-ICCSM2011-S0059.pdf>
- Shaobing Chen, & Donoho, D. (1994). Basis pursuit. *Proceedings of 1994 28th Asilomar Conference on Signals, Systems and Computers*, 1, 41–44. <https://doi.org/10.1109/ACSSC.1994.471413>
- Shen, L., Wang, S., Sun, G., Jiang, S., & Huang, Q. (2013). Multi-level discriminative

- dictionary learning towards hierarchical visual categorization. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 383–390. <https://doi.org/10.1109/CVPR.2013.56>
- Soliman, R. F., Amin, M., & Abd El-Samie, F. E. (2020). Cancelable Iris recognition system based on comb filter. *Multimedia Tools and Applications*, 79(3–4), 2521–2541. <https://doi.org/10.1007/s11042-019-08163-2>
- Song, Y., Cao, W., & He, Z. (2014). Robust iris recognition using sparse error correction model and discriminative dictionary learning. *Neurocomputing*, 137, 198–204. <https://doi.org/10.1016/j.neucom.2013.06.051>
- Sturm, R., & Larsson, M. (2009). Genetics of human iris color and patterns. *Pigment Cell & Melanoma Research*, 22, 544–562. <https://doi.org/10.1111/j.1755-148X.2009.00606.x>
- Subban, R., Susitha, N., & Mankame, D. P. (2018). Efficient iris recognition using Haralick features based extraction and fuzzy particle swarm optimization. *Cluster Computing*, 21(1), 79–90. <https://doi.org/10.1007/s10586-017-0934-0>
- Tambe, P. B., Kulhare, P. D., Nirmal, M. D., & Prajapati, P. G. (2013). *Image Processing (IP) Through Erosion and Dilation Methods*. 3(7), 285–289.
- Casia iris image database, (2004).
- Tan, T. (2019). *Casia Iris Database*. <http://biometrics.idealtest.org/findTotalDbByMode.do?mode=Iris>
- Tan, T., He, Z., & Sun, Z. (2010). Efficient and robust segmentation of noisy iris images for non-cooperative iris recognition. *Image and Vision Computing*, 28(2), 223–230. <https://doi.org/10.1016/J.IMAVIS.2009.05.008>
- Tang, W., Otero, I. R., Krim, H., & Dai, L. (2016). Analysis dictionary learning for scene classification. *IEEE Workshop on Statistical Signal Processing Proceedings, 2016-Augus(July)*. <https://doi.org/10.1109/SSP.2016.7551849>
- Tobji, R., Di, W., & Ayoub, N. (2019). FMnet: Iris segmentation and recognition by using fully and multi-scale CNN for biometric security. *Applied Sciences (Switzerland)*, 9(10), 1–17. <https://doi.org/10.3390/app9102042>
- Torrence, B. F., & Torrence, E. A. (2019). *The Student's Introduction to Mathematica and the Wolfram Language* (3rd ed.). Cambridge University Press. <https://doi.org/10.1017/9781108290937>
- Vyas, R., Kanumuri, T., Sheoran, G., & Dubey, P. (2019). Efficient iris recognition through curvelet transform and polynomial fitting. *Optik*, 185(February), 859–867. <https://doi.org/10.1016/j.ijleo.2019.04.015>
- Wang, H, Xia, Y., & Wang, Z. (2017). Dictionary learning-based image compression. *2017 IEEE International Conference on Image Processing (ICIP)*, 3235–3239. <https://doi.org/10.1109/ICIP.2017.8296880>
- Wang, Haoran, Yuan, C., Hu, W., & Sun, C. (2012). Supervised class-specific dictionary learning for sparse modeling in action recognition. *Pattern Recognition*, 45(11), 3902–3911. <https://doi.org/10.1016/j.patcog.2012.04.024>
- Wang, Q., Zhang, X., Li, M., Dong, X., Zhou, Q., & Yin, Y. (2012). Adaboost and multi-orientation 2D Gabor-based noisy iris recognition. *Pattern Recognition Letters*, 33(8), 978–983. <https://doi.org/10.1016/J.PATREC.2011.08.014>
- Wang, W.-C., Chen, L.-B., & Chang, W.-J. (2018). Development and Experimental Evaluation of Machine-Learning Techniques for an Intelligent Hairy Scalp Detection System. *Applied Sciences*, 8(6), 853. <https://doi.org/10.3390/app8060853>
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on*

- Image Processing*, 13(4), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- Wildes, R. (1997). Iris recognition: an emerging biometric technology. *Proceedings of the {IEEE}*, 85(9), 1348–1363. <https://doi.org/10.1109/5.628669>
- Wildes, R P, Asmuth, J. C., Green, G. L., Hsu, S. C., Kolczynski, R. J., Matey, J. R., & McBride, S. E. (n.d.). A system for automated iris recognition. *Proceedings of 1994 {IEEE} Workshop on Applications of Computer Vision*. <https://doi.org/10.1109/acv.1994.341298>
- Wildes, Richard P. (1997). Iris Recognition: an Emerging Biometric Approach. *PROCEEDINGS OF THE IEEE*, 85(9), 1348–1363.
- Winston, J. J., & Hemanth, D. J. (2019). A comprehensive review on iris image-based biometric system. *Soft Computing*, 23(19), 9361–9384. <https://doi.org/10.1007/s00500-018-3497-y>
- Xiong, Q., Zhang, X., Xu, X., & He, S. (2021). A modified chaotic binary particle swarm optimization scheme and its application in face-iris multimodal biometric identification. *Electronics (Switzerland)*, 10(2), 1–17. <https://doi.org/10.3390/electronics10020217>
- Yadav, V., Batham, S., Kumar Acharya, A., & Paul, R. (2014). Approach to accurate circle detection: Circular Hough Transform and Local Maxima concept. *2014 International Conference on Electronics and Communication Systems, ICECS 2014*, 1–5. <https://doi.org/10.1109/ECS.2014.6892577>
- Yager, N., & Amin, A. (2004). Fingerprint classification: a review. *Pattern Analysis and Applications*, 7(1), 77–93. <https://doi.org/10.1007/s10044-004-0204-7>
- Yan, R., Shao, L., & Liu, Y. (2013). Nonlocal hierarchical dictionary learning using wavelets for image denoising. *IEEE Transactions on Image Processing*, 22(12), 4689–4698. <https://doi.org/10.1109/TIP.2013.2277813>
- Yang, M., Liu, W., Luo, W., & Shen, L. (2016). Analysis-synthesis Dictionary Learning for Universality-particularity Representation Based Classification. *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence*, 2251–2257. <http://dl.acm.org/citation.cfm?id=3016100.3016213>
- Yang, M., Zhang, L., Yang, J., & Zhang, D. (2010). Metaface learning for sparse representation based face recognition. *Proceedings - International Conference on Image Processing, ICIP*, 1601–1604. <https://doi.org/10.1109/ICIP.2010.5652363>
- Yang, S., Liu, Z., Wang, M., Sun, F., & Jiao, L. (2011). Multitask dictionary learning and sparse representation based single-image super-resolution reconstruction. *Neurocomputing*, 74(17), 3193–3203. <https://doi.org/10.1016/j.neucom.2011.04.014>
- Yeh, C.-C. M., & Yang, Y.-H. (2012). Supervised Dictionary Learning for Music Genre Classification. *Proceedings of the 2Nd ACM International Conference on Multimedia Retrieval*, 55:1--55:8. <https://doi.org/10.1145/2324796.2324859>
- Yingzi, E. Du. (2006). Review of iris recognition: cameras, systems, and their applications. *Sensor Review*, 26(1), 66–69. <https://doi.org/10.1108/02602280610640706>
- Yong Wang, & Jiu-Qiang Han. (2005). Iris recognition using independent component analysis. *2005 International Conference on Machine Learning and Cybernetics*, 7, 4487–4492 Vol. 7. <https://doi.org/10.1109/ICMLC.2005.1527729>
- Yue, L., Shen, H., Li, J., Yuan, Q., Zhang, H., & Zhang, L. (2016). Image super-resolution: The techniques, applications, and future. *Signal Processing*, 128. <https://doi.org/10.1016/j.sigpro.2016.05.002>
- Zhang, Q., & Li, B. (2010). Discriminative K-SVD for Dictionary Learning in Face Recognition. *IEEE Computer Society Conference on Computer Vision and Pattern*

Recognition, 8.

- Zhao, T., Liu, Y., Huo, G., & Zhu, X. (2019). A Deep Learning Iris Recognition Method Based on Capsule Network Architecture. *IEEE Access*, 7, 49691–49701. <https://doi.org/10.1109/ACCESS.2019.2911056>
- Zheng, J., Jiang, Z., Phillips, J., & Chellappa, R. (2012). *Cross-View Action Recognition via a Transferable Dictionary Pair*. 125.1-125.11. <https://doi.org/10.5244/c.26.125>
- Zhong, Z., Li, Z., Li, R., & Sun, X. (2018). Unsupervised Domain Adaptation Dictionary Learning for Visual Recognition. In M. Ganji, L. Rashidi, B. C. M. Fung, & C. Wang (Eds.), *Trends and Applications in Knowledge Discovery and Data Mining* (pp. 16–26). Springer International Publishing.
- Zhou, M., Chen, H., Ren, L., Sapiro, G., Carin, L., & Paisley, J. W. (2009). Non-parametric Bayesian dictionary learning for sparse image representations. *Advances in Neural Information Processing Systems 22*, 2295–2303. <http://papers.nips.cc/paper/3851-non-parametric-bayesian-dictionary-learning-for-sparse-image-representations>
- Zhou, S., & Sun, J. (2013). A novel approach for code match in iris recognition. *2013 {IEEE}/{ACIS} 12th International Conference on Computer and Information Science ({ICIS})*. <https://doi.org/10.1109/icis.2013.6607828>
- Zubair, S., Yan, F., & Wang, W. (2013). Dictionary learning based sparse coefficients for audio classification with max and average pooling. *Digital Signal Processing: A Review Journal*, 23(3), 960–970. <https://doi.org/10.1016/j.dsp.2013.01.004>

EKLER

EK-1 Sadece K-TDA uygulanıp, elde edilen gri seviye görüntüler için [0-255] arası piksel değerleri kullanılarak YBİ metriği ile yapılan karşılaştırma sonuçları

Sıra	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
1	256	4	8	10	91	95.02
2	256	4	8	5	91	95.02
3	256	4	8	1	91.14	95.15
4	256	2	8	10	92.53	96.68
5	256	2	8	5	92.39	96.26
6	256	2	8	1	92.39	96.26
7	256	1	8	10	93.08	97.09
8	256	1	8	5	92.66	96.95
9	256	1	8	1	92.94	97.09
10	256	4	6	10	91.56	95.71
11	256	4	6	5	91.7	95.85
12	256	4	6	1	91.7	95.85
13	256	2	6	10	92.53	96.68
14	256	2	6	5	92.39	96.54
15	256	2	6	1	92.53	96.68
16	256	1	6	10	92.8	96.95
17	256	1	6	5	92.8	96.81
18	256	1	6	1	92.94	96.95
19	256	4	4	10	92.39	96.4
20	256	4	4	5	92.53	96.4
21	256	4	4	1	92.53	96.4
22	256	2	4	10	92.66	96.81
23	256	2	4	5	92.53	96.81
24	256	2	4	1	92.8	96.95
25	256	1	4	10	92.8	96.81
26	256	1	4	5	92.66	96.81
27	256	1	4	1	92.94	96.95
28	128	4	8	10	91.28	95.15
29	128	4	8	5	91.14	95.15
30	128	4	8	1	91.42	95.15
31	128	2	8	10	92.53	96.54
32	128	2	8	5	92.39	96.26
33	128	2	8	1	92.39	96.26
34	128	1	8	10	92.94	96.95
35	128	1	8	5	92.66	96.81
36	128	1	8	1	92.94	97.09
37	128	4	6	10	91.83	95.98
38	128	4	6	5	91.7	95.71
39	128	4	6	1	91.83	95.85
40	128	2	6	10	92.39	96.4
41	128	2	6	5	92.8	96.95

42	128	2	6	1	92.66	96.81
43	128	1	6	10	92.8	96.81
44	128	1	6	5	92.94	96.95
45	128	1	6	1	92.8	96.81
46	128	4	4	10	92.53	96.4
47	128	4	4	5	92.53	96.54
48	128	4	4	1	92.53	96.54
49	128	2	4	10	92.8	96.95
50	128	2	4	5	92.66	96.81
51	128	2	4	1	92.8	96.95
52	128	1	4	10	92.8	96.81
53	128	1	4	5	92.8	96.81
54	128	1	4	1	92.8	96.81
55	64	4	8	10	90.87	95.15
56	64	4	8	5	91.14	95.15
57	64	4	8	1	91.42	95.43
58	64	2	8	10	92.39	96.4
59	64	2	8	5	92.66	96.81
60	64	2	8	1	92.39	96.54
61	64	1	8	10	92.8	96.95
62	64	1	8	5	92.94	96.95
63	64	1	8	1	92.8	96.81
64	64	4	6	10	91.7	95.85
65	64	4	6	5	91.97	95.98
66	64	4	6	1	91.83	95.71
67	64	2	6	10	92.8	96.95
68	64	2	6	5	92.8	96.95
69	64	2	6	1	92.94	96.95
70	64	1	6	10	92.8	96.95
71	64	1	6	5	92.8	96.95
72	64	1	6	1	92.94	96.95
73	64	4	4	10	92.66	96.54
74	64	4	4	5	92.66	96.54
75	64	4	4	1	92.53	96.4
76	64	2	4	10	92.8	96.95
77	64	2	4	5	92.8	96.95
78	64	2	4	1	92.66	96.81
79	64	1	4	10	92.94	96.95
80	64	1	4	5	92.66	96.81
81	64	1	4	1	92.66	96.81
82	32	4	8	10	91.42	95.85
83	32	4	8	5	91.56	95.85
84	32	4	8	1	91.56	95.85
85	32	2	8	10	92.8	96.95
86	32	2	8	5	92.66	96.95
87	32	2	8	1	93.08	97.09
88	32	1	8	10	93.36	97.51

89	32	1	8	1	93.36	97.37
90	32	1	8	5	93.63	97.37
91	32	4	6	10	91.7	95.57
92	32	4	6	5	91.7	95.85
93	32	4	6	1	91.7	95.57
94	32	2	6	10	92.25	96.54
95	32	2	6	5	92.66	96.81
96	32	2	6	1	92.53	96.68
97	32	1	6	10	92.94	97.09
98	32	1	6	5	92.8	96.95
99	32	1	6	1	93.08	97.09
100	32	4	4	10	91.97	96.12
101	32	4	4	5	92.39	96.4
102	32	4	4	1	92.53	96.4
103	32	2	4	10	92.8	96.95
104	32	2	4	5	92.66	96.81
105	32	2	4	1	92.8	96.95
106	32	1	4	10	92.94	96.95
107	32	1	4	5	92.8	96.81
108	32	1	4	1	92.8	96.81
109	16	4	8	10	85.2	90.59
110	16	4	8	5	92.11	96.4
111	16	4	8	1	92.39	96.54
112	16	2	8	10	79.25	88.52
113	16	2	8	5	91.97	96.4
114	16	2	8	1	91.28	95.71
115	16	1	8	10	81.46	89.21
116	16	1	8	5	90.73	95.57
117	16	1	8	1	91.56	96.12
118	16	4	6	10	91.97	95.98
119	16	4	6	5	91.97	96.26
120	16	4	6	1	92.11	96.12
121	16	2	6	10	93.22	97.23
122	16	2	6	5	93.08	97.23
123	16	2	6	1	93.08	97.23
124	16	1	6	10	93.08	97.09
125	16	1	6	5	93.36	97.37
126	16	1	6	1	93.22	97.23
127	16	4	4	10	91.83	95.85
128	16	4	4	5	92.8	96.54
129	16	4	4	1	92.8	96.54
130	16	2	4	10	92.94	97.09
131	16	2	4	5	92.8	96.95
132	16	2	4	1	92.8	96.95
133	16	1	4	10	92.8	96.95
134	16	1	4	5	92.8	96.95
135	16	1	4	1	92.94	96.95

EK-2 K-TDA ve ardından HE uygulanıp, şablon çıkarılmış siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak OKH metriğine göre yapılmış karşılaştırma sonuçları

Sıra	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
1	256	4	8	10	69.7	99.58
2	256	4	8	5	69.01	99.44
3	256	4	8	1	68.46	99.44
4	256	2	8	10	75.38	99.44
5	256	2	8	5	76.34	99.72
6	256	2	8	1	74.27	99.58
7	256	1	8	10	74.55	99.58
8	256	1	8	5	76.34	99.44
9	256	1	8	1	75.24	99.44
10	256	4	6	10	75.38	99.72
11	256	4	6	5	74.41	99.44
12	256	4	6	1	75.24	99.44
13	256	2	6	10	74.68	99.44
14	256	2	6	5	74.55	99.58
15	256	2	6	1	75.93	99.58
16	256	1	6	10	75.24	99.44
17	256	1	6	5	74.28	99.44
18	256	1	6	1	75.13	99.44
19	256	4	4	10	75.65	99.58
20	256	4	4	5	75.1	99.44
21	256	4	4	1	77.17	99.44
22	256	2	4	10	75.1	99.58
23	256	2	4	5	76.21	99.58
24	256	2	4	1	76.9	99.58
25	256	1	4	10	75.51	99.44
26	256	1	4	5	74.31	99.44
27	256	1	4	1	75.79	99.44
28	128	4	8	10	69.15	99.44
29	128	4	8	5	68.87	99.44
30	128	4	8	1	68.04	99.44
31	128	2	8	10	74.68	99.72
32	128	2	8	5	74.96	99.58
33	128	2	8	1	75.51	99.72
34	128	1	8	10	75.24	99.58
35	128	1	8	5	75.65	99.72
36	128	1	8	1	74.82	99.58
37	128	4	6	10	74.13	99.72
38	128	4	6	5	73.85	99.44
39	128	4	6	1	73.99	99.58
40	128	2	6	10	77.31	99.58
41	128	2	6	5	75.24	99.58
42	128	2	6	1	74.82	99.44

43	128	1	6	10	75.1	99.44
44	128	1	6	5	74.55	99.44
45	128	1	6	1	74.55	99.58
46	128	4	4	10	77.73	99.58
47	128	4	4	5	75.93	99.58
48	128	4	4	1	76.34	99.58
49	128	2	4	10	75.1	99.72
50	128	2	4	5	75.24	99.44
51	128	2	4	1	76.34	99.44
52	128	1	4	10	75.38	99.44
53	128	1	4	5	76.62	99.44
54	128	1	4	1	75.51	99.58
55	64	4	8	10	68.74	99.58
56	64	4	8	5	69.7	99.44
57	64	4	8	1	67.35	99.58
58	64	2	8	10	75.24	99.58
59	64	2	8	5	75.1	99.72
60	64	2	8	1	76.9	99.72
61	64	1	8	10	76.62	99.72
62	64	1	8	5	75.93	99.58
63	64	1	8	1	76.34	99.58
64	64	4	6	10	73.16	99.58
65	64	4	6	5	74.13	99.58
66	64	4	6	1	74.68	99.72
67	64	2	6	10	76.07	99.44
68	64	2	6	5	75.38	99.58
69	64	2	6	1	76.48	99.58
70	64	1	6	10	74.96	99.44
71	64	1	6	5	75.79	95.58
72	64	1	6	1	74.27	95.58
73	64	4	4	10	76.21	99.58
74	64	4	4	5	76.48	99.58
75	64	4	4	1	74.82	99.58
76	64	2	4	10	74.96	99.58
77	64	2	4	5	74.82	99.58
78	64	2	4	1	76.34	99.72
79	64	1	4	10	75.65	99.44
80	64	1	4	5	75.38	99.44
81	64	1	4	1	74.68	99.44
82	32	4	8	10	67.08	99.44
83	32	4	8	5	67.63	99.44
84	32	4	8	1	67.63	99.44
85	32	2	8	10	74.41	99.58
86	32	2	8	5	74.41	99.44
87	32	2	8	1	74.13	99.44
88	32	1	8	10	81.18	99.58
89	32	1	8	5	75.24	99.44

90	32	1	8	1	74.96	99.58
91	32	4	6	10	72.75	99.58
92	32	4	6	5	73.85	99.58
93	32	4	6	1	74.82	99.44
94	32	2	6	10	80.22	99.72
95	32	2	6	5	72.75	99.58
96	32	2	6	1	76.07	99.58
97	32	1	6	10	74.55	99.44
98	32	1	6	5	75.51	99.44
99	32	1	6	1	75.59	99.58
100	32	4	4	10	76.48	99.58
101	32	4	4	5	75.93	99.58
102	32	4	4	1	76.34	99.72
103	32	2	4	10	75.1	99.58
104	32	2	4	5	76.07	99.58
105	32	2	4	1	77.45	99.58
106	32	1	4	10	74.82	99.44
107	32	1	4	5	75.79	99.44
108	32	1	4	1	75.51	99.44
109	16	4	8	10	42.32	99.03
110	16	4	8	5	54.21	99.44
111	16	4	8	1	43.15	99.3
112	16	2	8	10	38.36	99.17
113	16	2	8	5	55.18	99.3
114	16	2	8	1	49.65	98.89
115	16	1	8	10	39.55	99.58
116	16	1	8	5	54.35	99.44
117	16	1	8	1	56.01	99.17
118	16	4	6	10	73.16	99.44
119	16	4	6	5	72.06	99.44
120	16	4	6	1	71.92	99.58
121	16	2	6	10	75.24	99.44
122	16	2	6	5	74.13	99.58
123	16	2	6	1	73.44	99.58
124	16	1	6	10	74.96	99.44
125	16	1	6	5	75.1	99.58
126	16	1	6	1	73.02	99.58
127	16	4	4	10	73.72	99.58
128	16	4	4	5	77.04	99.44
129	16	4	4	1	77.45	99.58
130	16	2	4	10	77.04	99.72
131	16	2	4	5	75.24	99.44
132	16	2	4	1	75.1	99.72
133	16	1	4	10	76.9	99.58
134	16	1	4	5	75.38	99.58
135	16	1	4	1	75.93	99.58

EK-3 K-TDA ve ardından HE uygulanıp, şablon çıkarılmış siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak ÖU metriğine göre yapılmış karşılaştırma sonuçları

Sıra	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
1	256	4	8	10	17.7	99.58
2	256	4	8	5	17.28	99.58
3	256	4	8	1	15.49	99.58
4	256	2	8	10	9.54	99.3
5	256	2	8	5	10.23	99.3
6	256	2	8	1	9.4	99.44
7	256	1	8	10	11.47	99.44
8	256	1	8	5	10.23	99.3
9	256	1	8	1	12.3	99.72
10	256	4	6	10	12.58	99.72
11	256	4	6	5	14.1	99.3
12	256	4	6	1	10.78	99.3
13	256	2	6	10	10.37	99.3
14	256	2	6	5	9.68	99.3
15	256	2	6	1	11.89	99.3
16	256	1	6	10	10.92	99.3
17	256	1	6	5	9.4	99.17
18	256	1	6	1	10.92	99.44
19	256	4	4	10	10.23	99.17
20	256	4	4	5	11.61	99.44
21	256	4	4	1	9.12	99.44
22	256	2	4	10	10.37	99.58
23	256	2	4	5	11.06	99.3
24	256	2	4	1	10.65	99.3
25	256	1	4	10	10.23	99.44
26	256	1	4	5	9.95	99.3
27	256	1	4	1	10.09	99.58
28	128	4	8	10	14.1	99.58
29	128	4	8	5	17.84	99.58
30	128	4	8	1	16.32	99.72
31	128	2	8	10	10.51	99.3
32	128	2	8	5	11.06	99.3
33	128	2	8	1	11.34	99.72
34	128	1	8	10	9.82	99.3
35	128	1	8	5	11.34	99.3
36	128	1	8	1	11.06	99.3
37	128	4	6	10	13.55	99.58
38	128	4	6	5	11.89	99.86
39	128	4	6	1	12.58	99.3
40	128	2	6	10	9.95	99.3
41	128	2	6	5	10.51	99.3
42	128	2	6	1	11.06	99.44

43	128	1	6	10	9.54	99.44
44	128	1	6	5	9.4	99.3
45	128	1	6	1	9.4	99.3
46	128	4	4	10	10.65	99.3
47	128	4	4	5	12.03	99.17
48	128	4	4	1	12.58	99.44
49	128	2	4	10	10.78	99.3
50	128	2	4	5	11.75	99.44
51	128	2	4	1	13.55	99.44
52	128	1	4	10	9.12	99.44
53	128	1	4	5	10.09	99.44
54	128	1	4	1	11.34	99.58
55	64	4	8	10	18.53	99.44
56	64	4	8	5	17.56	99.58
57	64	4	8	1	16.87	99.44
58	64	2	8	10	10.65	99.44
59	64	2	8	5	12.86	99.58
60	64	2	8	1	10.92	99.17
61	64	1	8	10	10.92	99.3
62	64	1	8	5	8.85	99.3
63	64	1	8	1	11.06	99.3
64	64	4	6	10	12.86	99.72
65	64	4	6	5	11.61	99.44
66	64	4	6	1	13	99.17
67	64	2	6	10	10.09	99.44
68	64	2	6	5	11.89	99.58
69	64	2	6	1	11.34	99.44
70	64	1	6	10	11.06	99.3
71	64	1	6	5	10.92	99.3
72	64	1	6	1	10.78	99.17
73	64	4	4	10	9.82	99.58
74	64	4	4	5	12.03	99.44
75	64	4	4	1	11.2	99.3
76	64	2	4	10	10.65	99.17
77	64	2	4	5	10.09	99.44
78	64	2	4	1	11.06	99.17
79	64	1	4	10	9.12	99.44
80	64	1	4	5	10.23	99.3
81	64	1	4	1	11.34	99.44
82	32	4	8	10	18.94	99.44
83	32	4	8	5	18.94	99.44
84	32	4	8	1	16.04	99.44
85	32	2	8	10	12.03	99.17
86	32	2	8	5	11.47	99.4
87	32	2	8	1	11.61	99.3
88	32	1	8	10	17.28	99.44
89	32	1	8	5	12.72	99.03

90	32	1	8	1	11.75	99.3
91	32	4	6	10	13.27	99.58
92	32	4	6	5	12.17	99.86
93	32	4	6	1	12.03	99.3
94	32	2	6	10	16.04	99.58
95	32	2	6	5	9.4	99.58
96	32	2	6	1	10.78	99.3
97	32	1	6	10	10.23	99.44
98	32	1	6	5	11.75	99.3
99	32	1	6	1	10.37	99.58
100	32	4	4	10	10.37	99.72
101	32	4	4	5	13.13	99.3
102	32	4	4	1	10.37	99.3
103	32	2	4	10	10.92	99.86
104	32	2	4	5	11.47	99.44
105	32	2	4	1	11.61	99.44
106	32	1	4	10	11.06	99.44
107	32	1	4	5	9.4	99.44
108	32	1	4	1	11.34	99.3
109	16	4	8	10	1.79	99.03
110	16	4	8	5	22.68	99.17
111	16	4	8	1	23.78	99.17
112	16	2	8	10	1.52	99.03
113	16	2	8	5	19.36	99.03
114	16	2	8	1	23.51	99.17
115	16	1	8	10	1.24	99.03
116	16	1	8	5	16.18	99.03
117	16	1	8	1	19.77	99.17
118	16	4	6	10	13.83	99.58
119	16	4	6	5	14.79	99.58
120	16	4	6	1	13	99.3
121	16	2	6	10	12.44	99.3
122	16	2	6	5	12.44	99.3
123	16	2	6	1	10.51	99.72
124	16	1	6	10	6.5	99.03
125	16	1	6	5	11.75	99.3
126	16	1	6	1	13.27	99.44
127	16	4	4	10	13.83	99.58
128	16	4	4	5	10.23	99.3
129	16	4	4	1	12.72	99.58
130	16	2	4	10	9.26	99.17
131	16	2	4	5	10.78	99.58
132	16	2	4	1	13.27	99.3
133	16	1	4	10	9.68	99.3
134	16	1	4	5	11.75	99.3
135	16	1	4	1	9.54	99.17

EK-4 K-TDA ve ardından HE uygulanıp, şablon çıkarılmış siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak YBİ metriğine göre yapılmış karşılaştırma sonuçları

Sıra	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
1	256	4	8	10	90.59	92.53
2	256	4	8	5	90.04	92.53
3	256	4	8	1	89.62	92.53
4	256	2	8	10	88.24	91.14
5	256	2	8	5	89.34	92.25
6	256	2	8	1	89.34	91.83
7	256	1	8	10	88.52	91.42
8	256	1	8	5	88.93	91.83
9	256	1	8	1	87.96	91.28
10	256	4	6	10	90.17	93.08
11	256	4	6	5	89.76	91.97
12	256	4	6	1	89.76	92.66
13	256	2	6	10	88.52	91.7
14	256	2	6	5	88.38	91.83
15	256	2	6	1	87.69	91.56
16	256	1	6	10	87.41	91.28
17	256	1	6	5	88.79	92.66
18	256	1	6	1	88.1	91.97
19	256	4	4	10	88.38	90.87
20	256	4	4	5	88.52	91.56
21	256	4	4	1	90.04	92.94
22	256	2	4	10	88.1	92.11
23	256	2	4	5	87.96	92.66
24	256	2	4	1	89.9	92.25
25	256	1	4	10	88.79	91.97
26	256	1	4	5	87.13	90.73
27	256	1	4	1	88.24	91
28	128	4	8	1	90.04	93.08
29	128	4	8	5	89.9	92.11
30	128	4	8	10	89.9	92.66
31	128	2	8	1	87.82	91.42
32	128	2	8	5	88.24	91
33	128	2	8	10	88.38	91.56
34	128	1	8	1	87.82	90.87
35	128	1	8	5	88.79	91.97
36	128	1	8	10	87.55	90.45
37	128	4	6	1	90.04	92.8
38	128	4	6	5	90.31	92.8
39	128	4	6	10	90.31	92.8
40	128	2	6	1	88.38	91.83
41	128	2	6	5	87.55	91.7
42	128	2	6	10	90.31	93.08

43	128	1	6	1	88.1	91.56
44	128	1	6	5	87.55	91.56
45	128	1	6	10	88.79	91.14
46	128	4	4	1	89.62	92.11
47	128	4	4	5	88.65	91.42
48	128	4	4	10	89.34	91.14
49	128	2	4	1	88.65	91.83
50	128	2	4	5	88.79	91.97
51	128	2	4	10	88.93	92.11
52	128	1	4	1	88.24	91.56
53	128	1	4	5	87.27	91.56
54	128	1	4	10	87.41	91.14
55	64	4	8	10	91.14	92.66
56	64	4	8	5	90.31	93.22
57	64	4	8	1	89.9	92.66
58	64	2	8	10	88.52	91.56
59	64	2	8	5	88.79	91
60	64	2	8	1	87.82	91
61	64	1	8	10	88.24	91.14
62	64	1	8	5	88.79	92.39
63	64	1	8	1	88.93	92.25
64	64	4	6	10	88.93	92.11
65	64	4	6	5	89.62	91.56
66	64	4	6	1	88.93	91.83
67	64	2	6	10	88.65	91.56
68	64	2	6	5	89.76	92.66
69	64	2	6	1	89.9	91.42
70	64	1	6	10	88.52	92.53
71	64	1	6	5	88.65	92.25
72	64	1	6	1	89.07	92.25
73	64	4	4	10	88.65	92.11
74	64	4	4	5	89.21	92.39
75	64	4	4	1	89.34	91.83
76	64	2	4	10	87.55	91.28
77	64	2	4	5	89.34	91.83
78	64	2	4	1	88.1	91.42
79	64	1	4	10	87.27	91.7
80	64	1	4	5	87.82	91.28
81	64	1	4	1	87.96	91.83
82	32	4	8	10	90.31	92.66
83	32	4	8	5	90.45	92.39
84	32	4	8	1	89.9	92.66
85	32	2	8	10	88.93	91.56
86	32	2	8	5	88.52	91.42
87	32	2	8	1	88.24	92.11
88	32	1	8	10	87.27	90.45
89	32	1	8	5	87.82	91

90	32	1	8	1	87.69	91
91	32	4	6	10	89.07	92.66
92	32	4	6	5	90.45	91.97
93	32	4	6	1	89.07	91.97
94	32	2	6	10	88.79	91.83
95	32	2	6	5	87.27	91.14
96	32	2	6	1	87.82	91.14
97	32	1	6	10	88.1	91.7
98	32	1	6	5	88.79	92.39
99	32	1	6	1	88.65	92.11
100	32	4	4	10	89.34	92.11
101	32	4	4	5	88.93	92.25
102	32	4	4	1	89.07	91.7
103	32	2	4	10	89.21	92.25
104	32	2	4	5	88.93	91.97
105	32	2	4	1	88.52	91.97
106	32	1	4	10	86.44	90.87
107	32	1	4	5	88.38	92.53
108	32	1	4	1	87.55	92.11
109	16	4	8	10	76.76	78.56
110	16	4	8	5	87.13	89.34
111	16	4	8	1	87.41	90.31
112	16	2	8	10	61.96	68.87
113	16	2	8	5	86.49	90.04
114	16	2	8	1	87.55	89.07
115	16	1	8	10	62.1	69.57
116	16	1	8	5	85.06	88.1
117	16	1	8	1	86.99	89.21
118	16	4	6	10	90.45	92.66
119	16	4	6	5	90.31	92.53
120	16	4	6	1	89.9	92.25
121	16	2	6	10	88.24	91.7
122	16	2	6	5	88.65	92.25
123	16	2	6	1	90.04	92.11
124	16	1	6	10	87.13	90.59
125	16	1	6	5	88.93	92.39
126	16	1	6	1	89.07	91.83
127	16	4	4	10	89.62	91.83
128	16	4	4	5	89.48	91.7
129	16	4	4	1	89.21	92.66
130	16	2	4	10	89.34	91.56
131	16	2	4	5	88.93	92.39
132	16	2	4	1	89.34	91.97
133	16	1	4	10	88.65	91.28
134	16	1	4	5	88.24	91.42
135	16	1	4	1	88.38	91.42

EK-5 K-TDA ve ardından HE uygulanıp, şablon çıkarılmış siyah-beyaz görüntüler için piksel değerleri ([0-1]) kullanılarak HU metriğine göre yapılmış karşılaştırma sonuçları

Sıra	Sözlük Atom Sayısı	Hata Hedefi	Blok Boyutu	İterasyon Sayısı	Yalnız 1. adım çalıştırıldığında (%)	Tüm adımlar çalıştırıldığında (%)
1	256	4	8	10	34.99	99.17
2	256	4	8	5	35.26	99.03
3	256	4	8	1	35.13	99.17
4	256	2	8	10	40.11	99.03
5	256	2	8	5	39.55	99.03
6	256	2	8	1	42.32	99.17
7	256	1	8	10	41.35	99.3
8	256	1	8	5	42.32	99.3
9	256	1	8	1	42.18	99.3
10	256	4	6	10	40.66	99.44
11	256	4	6	5	73.29	99.17
12	256	4	6	1	41.21	99.44
13	256	2	6	10	42.73	99.3
14	256	2	6	5	39.83	99.3
15	256	2	6	1	39.69	99.3
16	256	1	6	10	41.9	99.3
17	256	1	6	5	44.95	99.17
18	256	1	6	1	38.72	99.3
19	256	4	4	10	40.52	99.03
20	256	4	4	5	40.94	99.3
21	256	4	4	1	38.86	99.03
22	256	2	4	10	41.9	99.3
23	256	2	4	5	45.78	99.17
24	256	2	4	1	42.87	99.3
25	256	1	4	10	41.49	99.17
26	256	1	4	5	41.77	99.17
27	256	1	4	1	42.46	99.3
28	128	4	8	10	36.92	99.17
29	128	4	8	5	36.09	99.3
30	128	4	8	1	37.2	99.3
31	128	2	8	10	42.18	99.17
32	128	2	8	5	40.11	99.3
33	128	2	8	1	43.56	99.44
34	128	1	8	10	41.77	99.3
35	128	1	8	5	43.29	99.3
36	128	1	8	1	43.29	99.3
37	128	4	6	10	38.03	99.17
38	128	4	6	5	39.41	99.3
39	128	4	6	1	40.11	99.3
40	128	2	6	10	44.12	99.3
41	128	2	6	5	40.24	99.3
42	128	2	6	1	40.94	99.3

43	128	1	6	10	41.9	99.3
44	128	1	6	5	42.46	99.3
45	128	1	6	1	43.15	99.3
46	128	4	4	10	41.07	99.03
47	128	4	4	5	44.12	99.17
48	128	4	4	1	42.18	99.03
49	128	2	4	10	40.8	99.3
50	128	2	4	5	41.21	99.03
51	128	2	4	1	45.5	99.44
52	128	1	4	10	41.07	99.3
53	128	1	4	5	42.04	99.3
54	128	1	4	1	42.18	99.3
55	64	4	8	10	37.75	99.03
56	64	4	8	5	37.06	99.17
57	64	4	8	1	34.02	99.17
58	64	2	8	10	39.97	99.3
59	64	2	8	5	44.26	99.3
60	64	2	8	1	44.26	99.17
61	64	1	8	10	43.01	99.3
62	64	1	8	5	43.43	99.3
63	64	1	8	1	43.98	99.3
64	64	4	6	10	36.92	99.03
65	64	4	6	5	38.03	99.44
66	64	4	6	1	38.45	99.17
67	64	2	6	10	39.28	99.3
68	64	2	6	5	39.83	99.17
69	64	2	6	1	42.32	99.44
70	64	1	6	10	41.77	99.17
71	64	1	6	5	42.04	99.3
72	64	1	6	1	36.92	99.3
73	64	4	4	10	43.84	99.3
74	64	4	4	5	41.77	99.03
75	64	4	4	1	42.18	99.3
76	64	2	4	10	43.56	99.3
77	64	2	4	5	41.49	99.3
78	64	2	4	1	42.6	99.03
79	64	1	4	10	41.63	99.3
80	64	1	4	5	42.73	99.17
81	64	1	4	1	40.8	99.3
82	32	4	8	10	37.34	99.17
83	32	4	8	5	34.57	99.03
84	32	4	8	1	36.51	99.17
85	32	2	8	10	42.46	99.3
86	32	2	8	5	42.87	99.44
87	32	2	8	1	40.38	99.3
88	32	1	8	10	52.28	99.3
89	32	1	8	5	43.7	99.3

90	32	1	8	1	40.24	99.03
91	32	4	6	10	39	99.17
92	32	4	6	5	40.8	99.44
93	32	4	6	1	41.07	99.03
94	32	2	6	10	51.59	99.44
95	32	2	6	5	43.15	99.44
96	32	2	6	1	41.35	99.3
97	32	1	6	10	42.18	99.44
98	32	1	6	5	42.46	99.3
99	32	1	6	1	42.46	99.3
100	32	4	4	10	45.36	99.44
101	32	4	4	5	43.15	99.3
102	32	4	4	1	44.95	99.17
103	32	2	4	10	42.87	99.17
104	32	2	4	5	40.11	99.3
105	32	2	4	1	44.12	99.44
106	32	1	4	10	41.35	99.3
107	32	1	4	5	41.63	99.3
108	32	1	4	1	41.35	99.3
109	16	4	8	10	22.95	99.03
110	16	4	8	5	27.52	99.17
111	16	4	8	1	30.01	99.17
112	16	2	8	10	17.7	99.03
113	16	2	8	5	28.63	99.03
114	16	2	8	1	26.27	99.03
115	16	1	8	10	17.01	99.03
116	16	1	8	5	25.58	99.03
117	16	1	8	1	25.86	99.03
118	16	4	6	10	42.6	99.03
119	16	4	6	5	38.45	99.17
120	16	4	6	1	35.54	99.3
121	16	2	6	10	41.63	99.44
122	16	2	6	5	36.23	99.17
123	16	2	6	1	42.18	99.3
124	16	1	6	10	42.6	99.3
125	16	1	6	5	41.9	99.3
126	16	1	6	1	38.45	99.17
127	16	4	4	10	41.21	99.3
128	16	4	4	5	41.77	99.3
129	16	4	4	1	42.6	99.44
130	16	2	4	10	41.49	99.3
131	16	2	4	5	39.28	99.17
132	16	2	4	1	42.18	99.44
133	16	1	4	10	41.21	99.3
134	16	1	4	5	40.94	99.3
135	16	1	4	1	40.8	99.3