



**GELENEKSEL ÖZNİTELİK ÇIKARMA
YÖNTEMLERİ KULLANARAK DERİN
ÖĞRENME TABANLI YÜZ TANIMA**

YÜKSEK LİSANS TEZİ

Halit TÜRBEDAR

Danışman

Dr. Öğr. Üyesi Fatih BAYRAM

MEKATRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

Haziran 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

GELENEKSEL ÖZNİTELİK ÇIKARMA YÖNTEMLERİ
KULLANARAK DERİN ÖĞRENME TABANLI YÜZ TANIMA

Halit TÜRBEDAR

Danışman

Dr. Öğr. Üyesi Fatih BAYRAM

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2025

TEZ ONAY SAYFASI

Halit TRBEDAR tarafından hazırlanan ‘‘Geleneksel znitelik ıkarma yntemleri kullanarak derin ğrenme tabanlı yz tanıma’’ adlı tez alışması lisansst eğitim ve ğretim ynetmeliğinin ilgili maddeleri uyarınca 23 / 06 / 2025 tarihinde ařağıdaki jri tarafından **oy birliğı** ile Afyon Kocatepe niversitesi Fen Bilimleri Enstits **Mekatronik Mhendisliğı Anabilim Dalı’nda YKSEK LİSANS TEZİ** olarak kabul edilmiřtir.

Danışman : Dr. ğr. yesi Fatih BAYRAM

İmza

Başkan : Doç. Dr. Emin İBİLİ
Afyonkarahisar Sağık Bilimleri niversitesi,
Sağık Bilimleri Fakltesi

.....

ye : Dr. ğr. yesi Fatih BAYRAM
Afyon Kocatepe niversitesi,
Teknoloji Fakltesi

.....

ye : Doç. Dr. Gray SONUGR
Afyon Kocatepe niversitesi,
Teknoloji Fakltesi

.....

Afyon Kocatepe niversitesi
Fen Bilimleri Enstits Ynetim Kurulu’nun
..... / / tarih ve
..... sayılı kararıyla onaylanmıřtır.

.....

Prof. Dr. Bekir YALÇIN
Enstit Mdr

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

23 / 06 / 2025

Halit TÜRBEDAR

ÖZET

Yüksek Lisans Tezi

GELENEKSEL ÖZNİTELİK ÇIKARMA YÖNTEMLERİ KULLANARAK DERİN ÖĞRENME TABANLI YÜZ TANIMA

Halit TÜRBEDAR

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Mekatronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Fatih BAYRAM

Bu araştırmada, yüz tanıma problemlerine yönelik olarak Griseviye, HOG ve LBP gibi geleneksel öznitelik çıkarım yöntemlerinin birleşimiyle oluşturulan hibrit özellikler, derin öğrenme modelleriyle bütünleştirilmiş ve ORL, PUT, Yale, Georgia ve FERET olmak üzere beş farklı veri seti üzerinde değerlendirilmiştir. Her veri seti için eğitim, doğrulama ve test oranları veri setinin büyüklüğüne ve çeşitliliğine göre belirlenmiştir. Deneysel sonuçlar, geliştirilen modelin çoğu veri setinde %99'a varan eğitim doğruluğu ve %95–%99 aralığında test doğruluğu sağladığını ortaya koymaktadır. Ayrıca kesinlik, duyarlılık ve F1-skor gibi ek değerlendirme metrikleri de tüm veri setlerinde %95'in üzerinde gerçekleşmiştir. Karmaşıklık matrisi analizleri, modelin sınıf içi benzerliklere rağmen yüksek genelleme yeteneğine sahip olduğunu göstermektedir. Bu sonuçlar, önerilen hibrit modelin yalnızca geleneksel yöntemlerden üstün olduğunu değil, aynı zamanda düşük veri hacmine sahip ortamlarda dahi güvenilir ve ölçeklenebilir bir şekilde çalışabildiğini ortaya koymaktadır.

Anahtar Kelimeler: Yüz Tanıma, Derin Öğrenme, HOG, LBP, Griseviye, Öznitelik Birleştirme.

ABSTRACT

M.Sc. Thesis

DEEP LEARNING-BASED FACE RECOGNITION USING CONVENTIONAL FEATURE EXTRACTION METHODS

Halit TÜRBEDAR

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Mechatronic Engineering

Supervisor: Asst. Prof. Fatih BAYRAM

In this study, hybrid features were constructed by combining traditional feature extraction techniques such as Grayscale, HOG, and LBP, and integrated with deep learning models for the purpose of solving face recognition problems. The proposed system was evaluated on five different face datasets: ORL, PUT, Yale, Georgia, and FERET. The training, validation, and test splits were tailored for each dataset according to their size and diversity. Experimental results show that the proposed model achieved up to 99% training accuracy and between 95% and 99% test accuracy across most datasets. Additional evaluation metrics such as precision, recall, and F1-score were also above 95% for all datasets. Confusion matrix analysis revealed that the model performs well even in the presence of intra-class similarities. These results confirm that the hybrid model not only surpasses conventional methods but also provides reliable and scalable performance even with limited data.

Keywords: Face Recognition, Deep Learning, HOG, LBP, Grayscale, Feature Fusion.

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Fatih BAYRAM'a, her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerinden dolayı aileme teşekkür ederim.

Halit TÜRBEDAR
Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER DİZİNİ	iv
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. LİTERATÜR BİLGİLERİ	3
2.1. Yüz Tanıma Tarihi	3
2.1.1. Temel Bileşenler Analizi (PCA - Eigenfaces)	3
2.1.2. Yerel Özellik Analizi (LFA)	4
2.1.3. Fisherface	4
2.1.4. Elastik Demet Grafik Eşleme (EBGM).....	5
2.1.5. Bağımsız Bileşenler Analizi (ICA)	6
2.1.6. HOG – EBGM Tabanlı Yüz Tanıma	6
2.1.7. Seyrek Temsil Tabanlı Sınıflandırma (SRC)	7
2.1.8. HOG ve DMMA Tabanlı Tek Örnekli Yüz Tanıma	7
2.1.9. HOG-PCA ve Morfolojik-Aritmetik İşlemlerle Pseudo-Sketch Tabanlı Yüz Tanıma	8
2.1.10. Üçgensel Bulanık Küme ve LDP ile Dalgacık Tabanlı Yüz Tanıma.....	9
2.1.11. HOG–LDB ve SVDL Kullanarak Yüz Tanıma	9
2.1.12. HOG-ESR ve Paylaşılan Temsiller Topluluğu (ESR)	10
2.1.13. BPSO ve SVM Tabanlı Derin Özellik Seçimi ile Yüz Duygu Tanıma	11

3. MATERYAL ve METOT	12
3.1. Yazılım	12
3.1.1. Kullanılan Programlama Dili ve Ara Yüzü.....	12
3.1.2. Kullanılan Kütüphaneler	13
3.1.2.1. Sklearn Kütüphanesi	13
3.1.2.2. Keras Kütüphanesi	14
3.1.2.3. Imblearn Kütüphanesi	15
3.1.2.4. TF (Tensorflow) Kütüphanesi	15
3.1.2.5. matplotlib.pyplot Kütüphanesi.....	16
3.1.2.6. Pd (Pandas) Kütüphanesi	16
3.1.2.7. NumPy Kütüphanesi	16
3.1.2.8. Scipy Kütüphanesi	16
3.1.2.9. Skimage Kütüphanesi	17
3.1.2.10. Opencv Kütüphanesi.....	17
3.1.2.11. Os Kütüphanesi.....	17
3.1.3. Yazılımda Kullanılan Yöntemler	18
3.1.3.1. Fonksiyonlar	18
3.2. Kullanılan Veri Seti.....	18
3.2.1. Feret Veri Seti	18
3.2.2. Georgia Veri Seti.....	19
3.2.3. Orl Veri Seti	20
3.2.4. Put Veri Seti	21
3.2.5. Yale Veri Seti	22
3.2.6. Veri Setlerinin Karşılaştırması	23
3.3. Kullanılan Yöntem	25

3.3.1. Yönlendirilmiş Gradyan Histogramları (HOG)	26
3.3.2. Yerel İkili Desen (LBP)	27
3.3.3. Griseviye Dönüşümü.....	27
3.3.4. Derin Öğrenme Modeli	28
3.3.5. Veri Artırımı.....	32
3.3.5.1. Yatay Yansıtma.....	32
3.3.5.2. Görüntü Kaydırma	32
3.3.5.3. Görüntü Döndürme	32
3.3.5.4. Görüntülerin Ölçeklendirilmesi	32
3.3.6. Kullanılan Derin Öğrenme Metrikleri.....	33
3.3.6.1. Doğruluk (Accuracy)	33
3.3.6.2. Karmaşıklık Matrisi (Confusion Matrix)	33
3.3.6.3. Hassasiyet (Precision).....	34
3.3.6.4. Duyarlık (Recall)	34
3.3.6.5. F1 Skoru (F1 Score).....	34
4. BULGULAR.....	36
4.1. Çalışmanın Genel Bakışı	36
4.2. ORL Veri Seti Sonuçları	36
4.2.1. Eğitim ve Doğrulama Sonuçları.....	36
4.2.2. Test Sonuçları.....	37
4.2.3. Ek Değerlendirme Metrikleri	38
4.2.4. Yorum ve Değerlendirme.....	39
4.3. PUT Veri Seti Sonuçları.....	40
4.3.1. Eğitim ve Doğrulama Sonuçları.....	40
4.3.2. Test Sonuçları.....	41

4.3.3. Ek Değerlendirme Metrikleri	41
4.3.4. Yorum ve Değerlendirme	42
4.4. Yale Veri Seti Sonuçları	43
4.4.1. Eğitim ve Doğrulama Sonuçları	43
4.4.2. Test Sonuçları	43
4.4.3. Ek Değerlendirme Metrikleri	45
4.4.4. Yorum ve Değerlendirme	45
4.5. Georgia Veri Seti Sonuçları	47
4.5.1. Eğitim ve Doğrulama Sonuçları	47
4.5.2. Test Sonuçları	49
4.5.3. Ek Değerlendirme Metrikleri	49
4.5.4. Yorum ve Değerlendirme	49
4.6. Feret Veri Seti Sonuçları	50
4.6.1. Eğitim ve Doğrulama Sonuçları	51
4.6.2. Test Sonuçları	52
4.6.3. Ek Değerlendirme Metrikleri	52
4.6.4. Yorum ve Değerlendirme	53
5. TARTIŞMA ve SONUÇ	55
6. KAYNAKLAR	60

SİMGELER ve KISALTMALAR DİZİNİ

Kısaltmalar

BPSO	İkili Parçacık Sürü Optimizasyonu
CNN	Konvolüsyonel Sinir Ağı
DMMA	Ayırt Edici Çoklu Çeşitli Manifold Analizi
DWT	Ayrık Dalgacık Dönüşümü
EBGM	Elastik Demet Grafik Eşleme
ESR	Paylaşılan Temsiller Topluluğu
FERET	Yüz Tanıma Teknolojisi
GTDB	Georgia Tech Face Database
HOG	Yönlendirilmiş Gradyan Histogramları
ICA	Bağımsız Bileşenler Analizi
KNN	En Yakın Komşu
LBP	Yerel İkili Desen
LCP	Yerel Çapraz Desen
LDA	Doğrusal Ayırıcı Analiz
LDB	Yerel Fark İkili
LFA	Yerel Özellik Analizi
NNC	En Yakın Komşu Sınıflandırıcısı
ORL	Olivetti Research Laboratory
PCA	Temel Bileşenler Analizi
PUT	Poznan Teknoloji Üniversitesi
QDA	Kuadratik Ayırıcı Analiz
SRC	Seyrek Temsil Tabanlı Sınıflandırma
SVDL	Seyrek Varyasyon Sözlüğü Öğrenme
SVM	Destek Vektör Makineleri

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1 Feret veri seti örnek görüntüler	19
Şekil 3.2 Georgia veri seti örnek görüntüler	20
Şekil 3.3 Orl veri Seti örnek görüntüler	21
Şekil 3.4 Put veri seti örnek görüntüler	22
Şekil 3.5 Yale veri seti örnek görüntüler	23
Şekil 3.6 Yöntemin akış şeması	25
Şekil 3.7 HOG yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü	26
Şekil 3.8 LBP yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü	27
Şekil 3.9 Griseviye yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü	28
Şekil 3.10 Geliştirilen CNN modelinin mimari şeması	30
Şekil 3.11 Derin öğrenme modelinin akış şeması	31
Şekil 4.1 ORL veri seti doğruluk grafiği	37
Şekil 4.2 ORL veri seti hata grafiği	37
Şekil 4.3 ORL veri setin karmaşıklık matrisinden örnek görüntüler	38
Şekil 4.4 ORL veri seti üzerinde uygulanan farklı yüz tanıma yöntemlerinin doğruluk oranlarının karşılaştırılması	39
Şekil 4.5 PUT veri seti doğruluk grafiği	40
Şekil 4.6 PUT veri seti kayıp grafiği	41
Şekil 4.7 PUT veri seti karmaşıklık matrisinden örnek görüntüler	42
Şekil 4.8 Yale veri seti doğruluk grafiği	44
Şekil 4.9 Yale veri seti kayıp grafiği	44

Şekil 4.10 Yale veri seti karmaşıklık matrisinden örnek görüntüler	46
Şekil 4.11 Yale veri seti üzerinde literatürdeki yöntemler ile HOG, LBP, Griseviye + derin öğrenme yönteminin karşılaştırması.....	47
Şekil 4.12 Georgia veri seti doğruluk grafiği	48
Şekil 4.13 Georgia veri seti kayıp grafiği	48
Şekil 4.14 Georgia veri seti karmaşıklık matrisinden örnek görüntüler	50
Şekil 4.15 Feret veri seti doğruluk grafiği.....	51
Şekil 4.16 Feret veri seti hata grafiği	52
Şekil 4.17 Feret veri seti karmaşıklık matrisinden örnek görüntüler	53
Şekil 4.18 FERET veri seti üzerinde literatürdeki yöntemler ile HOG, LBP, Griseviye + derin öğrenme yönteminin karşılaştırması.....	54
Şekil 5.1 Veri setlerine göre sınıf ve görüntü sayıları.....	56
Şekil 5.2 Veri setlerine göre eğitim ve doğrulama doğruluk oranları	57
Şekil 5.3 Veri setlerine göre eğitim ve doğrulama hata oranları.....	58

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Yüz tanıma veri setlerinin karşılaştırması	24
Çizelge 5.1 Veri setlerine ait sınıf, görüntü sayısı ve bölme oranları	55



1. GİRİŞ

Günümüzde biyometrik sistemler, kimlik doğrulama ve güvenlik uygulamalarında artan bir şekilde kullanılmaktadır. Bu sistemler arasında yüz tanıma teknolojileri, kullanıcıdan herhangi bir fiziksel etkileşim gerektirmemesi ve insan tarafından doğal olarak algılanabilmesi gibi avantajlarıyla ön plana çıkmaktadır. Özellikle artan güvenlik ihtiyaçları, dijital kimlik doğrulama sistemleri, akıllı gözetim uygulamaları ve insan-bilgisayar etkileşimi gibi pek çok alanda yüz tanıma sistemlerinin uygulanabilirliğini ve önemini artırmıştır.

Yüz tanıma süreci genel olarak dört temel adımdan oluşur: yüzün tespiti, öznitelik çıkarımı, özelliklerin seçimi ve sınıflandırma. Bu süreçte başarıyı etkileyen en kritik adımlardan biri, görüntüden anlamlı ve ayırt edici özniteliklerin çıkarılmasıdır. Bu nedenle, öznitelik çıkarımı üzerine yapılan araştırmalar, yüz tanıma performansını artırmaya yönelik çalışmaların odak noktası hâline gelmiştir. Özellikle Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP), Local Directional Binary Patterns (LDB) ve Griseviye dönüşümleri gibi geleneksel yöntemler, düşük karmaşıklıkları ve güçlü ayırt edicilik yetenekleri nedeniyle yaygın şekilde tercih edilmektedir.

Ancak bu geleneksel yöntemlerin sınırlı örnek sayısı, değişken aydınlatma, poz varyasyonları ve arka plan farklılıkları karşısında genelleme kapasiteleri sınırlı kalabilmektedir. Bu noktada derin öğrenme mimarileri, yüksek düzeyde özellik çıkarma ve öğrenme kapasitesi sayesinde önemli avantajlar sağlamaktadır. Bu çalışmada, geleneksel öznitelik çıkarım yöntemleriyle elde edilen özniteliklerin, derin öğrenme tabanlı bir sınıflandırma mimarisi ile bütünleştirilmesi hedeflenmiştir.

Bu tez kapsamında, Griseviye, HOG ve LBP yöntemleriyle öznitelikler çıkarılmış, ardından bu öznitelikler birleştirilerek derin öğrenme modellerine giriş olarak verilmiştir. Geliştirilen hibrit sistem, yüz tanıma alanında sıklıkla kullanılan ORL, PUT, Yale, Georgia ve FERET veri setleri üzerinde test edilerek değerlendirilmiştir. Her bir veri seti

iin eđitim, dođrulama ve test oranları veri setinin byklđne ve rnek eřitliliđine gre dikkatle belirlenmiřtir.

alıřmanın temel amacı, geleneksel ve modern yaklařımların birleřtirilmesiyle elde edilen bu hibrit modelin, farklı veri setlerinde nasıl performans gsterdiđini incelemek ve elde edilen sonuları literatrdeki diđer yntemlerle karřılařtırmaktır. Ayrıca modelin genelleme yeteneđi, sınıflar arası ayırım gc ve istikrarı gibi ynleri, detaylı istatistiksel metriklerle analiz edilmiřtir.

Bu dođrultuda tezde; literatr zeti, kullanılan yntemler, deneysel dzenekler, elde edilen bulgular ve bu bulguların deđerlendirilmesine dair blmler sunulmuřtur. Sonu olarak nerilen sistemin, geleneksel yntemlere kıyasla daha yksek dođruluk ve kararlılık sunduđu ortaya konmuřtur.

2. LİTERATÜR BİLGİLERİ

2.1. Yüz Tanıma Tarihi

Yüz tanıma, insan kimliğinin görsel özellikler üzerinden otomatik olarak tespit edilmesi amacıyla geliştirilmiş bir biyometrik tanıma yöntemidir. Bu alandaki bilimsel çalışmaların temelleri 1960'lı yıllarda atılmıştır. Özellikle 1964–1965 yıllarında Woodrow W. Bledsoe tarafından yürütülen öncü araştırmalar, bilgisayar destekli yüz tanımanın ilk somut adımlarını temsil etmektedir. Bledsoe, yüz görüntülerinde göz, burun ve ağız gibi belirli ölçüm noktalarını manuel olarak işaretleyerek bir veri tabanı oluşturmuş ve bu verileri kullanarak tanıma sistemleri geliştirmeye çalışmıştır. Ancak söz konusu çalışmalar, gizlilik derecesi yüksek devlet projeleri kapsamında yürütüldüğü için kamuoyuyla paylaşılmamıştır (Bledsoe, 1964).

Dönemin teknolojik altyapısının ve algoritmik yöntemlerinin henüz yeterince gelişmemiş olması, ayrıca finansman ve veri eksikliği gibi pratik engeller, bu alandaki bilimsel ilerlemenin erken dönemde sınırlı kalmasına neden olmuştur. 1990'lı yıllarla birlikte bilgisayar teknolojilerindeki gelişmeler ve görüntü işleme algoritmalarının yaygınlaşması, yüz tanıma araştırmalarının yeniden ivme kazanmasını sağlamıştır. Bu bağlamda, bu bölümde yüz tanıma teknolojilerine yönelik bilimsel çalışmaların tarihsel gelişim süreci ayrıntılı olarak ele alınacaktır.

2.1.1. Temel Bileşenler Analizi (PCA - Eigenfaces)

İlk dönem yüz tanıma yöntemleri, insan yüzünün göz, burun ve ağız gibi belirgin yapısal özelliklerine dayalı olarak gerçekleştirilen manuel ölçümlere dayanıyordu. Ancak 1990'lı yıllarda bilgisayarla görme (computer vision) alanındaki teknolojik ilerlemeler sayesinde yüz tanıma algoritmaları kayda değer gelişmeler göstermiştir. Bu dönemde öne çıkan yaklaşımlardan biri olan Temel Bileşen Analizi (Principal Component Analysis – PCA) tabanlı Eigenfaces yöntemi, boyut indirgeme ve desen tanıma tekniklerini bir araya getirerek alana yeni bir soluk getirmiştir. Söz konusu yöntem, yüz görüntülerini PCA ile

elde edilen öznitelik uzayında temsil etmekte ve bu özniteliklerin ağırlıkları üzerinden sınıflandırma yapılmasına olanak tanımaktadır (Turk ve Pentland, 1991).

Eigenfaces yaklaşımı; hızlı ve verimli çalışması, denetimsiz öğrenmeye imkân tanınması ve yeni yüzlerin sisteme kolayca eklenebilmesi gibi avantajlar sunmaktadır. Ancak yöntemin; değişken aydınlatma koşulları, baş pozisyonu ve yönelimi gibi çevresel faktörlere karşı hassasiyeti, uygulama başarımını sınırlandıran temel zorluklar arasında yer almaktadır.

2.1.2. Yerel Özellik Analizi (LFA)

Yerel Özellik Analizi (Local Feature Analysis – LFA), Temel Bileşen Analizi'ne (Principal Component Analysis – PCA) bir alternatif olarak önerilen bir yaklaşımdır. Bu yöntem, PCA'nın sağladığı pratik avantajları korurken; nesnelerin yerel, topografik ve düşük boyutlu temsillerini oluşturarak daha ayrıntılı ve konuma duyarlı öznitelik çıkarımı sağlamaktadır. LFA, yalnızca iki boyutlu (2B) yüz görüntülerine değil, aynı zamanda üç boyutlu (3B) insan başı yüzeylerine ve arka plan içeren karmaşık sahne görüntülerine de uygulanabilmekte; bu sayede baş segmentasyonu ve yüz tanıma gibi alanlarda güçlü ve esnek çözümler sunmaktadır (Penev ve Atick, 1996).

2.1.3. Fisherface

Fisherface yöntemi, PCA tabanlı Eigenface yaklaşımına kıyasla değişen aydınlatma koşulları ve yüz ifadeleri altında daha üstün bir tanıma performansı sergilemektedir. Bu yöntem, Fisher'in Doğrusal Ayırma Analizi (Linear Discriminant Analysis – LDA) yöntemini kullanarak sınıflar arası ayrımı maksimize eder ve böylece sınıflandırma doğruluğunu artırmayı hedefler. Özellikle aydınlatma ve ifade farklılıklarının belirgin olduğu durumlarda, Fisherface yöntemi Eigenface'e göre bariz bir avantaj sağlamaktadır.

Belhumeur, Hespanha ve Kriegman tarafından yapılan kapsamlı bir çalışmada, farklı yüz ifadeleri ve değişken aydınlatma koşullarını içeren YALE veri seti kullanılarak bu iki yöntemin karşılaştırmalı analizi gerçekleştirilmiştir. Çalışma aynı zamanda, aşırı

aydınlatma senaryolarında yüz tanımanın zorluklarına dikkat çekmekte ve tüm olası aydınlatma koşullarında yüz görüntülerinin düşük boyutlu bir uzayda dışbükey bir koni oluşturduğu varsayımını öne sürmektedir. "Leaving-One-Out" protokolüyle yapılan deneylerde PCA tabanlı Eigenface yöntemi, 30 boyutlu uzayda %24,4 (Close Crop) ve %19,4 (Full Face) hata oranı ile ölçülürken; ilk üç bileşenin çıkarılmasıyla bu oranlar %15,3 ve %10,8'e düşürülmüştür. Buna karşılık Fisherface yöntemi, yalnızca 15 boyut kullanılarak %7,3 (Close Crop) ve %0,6 (Full Face) gibi oldukça düşük hata oranları ile en başarılı sonucu elde etmiştir (Belhumeur vd., 1997).

2.1.4. Elastik Demet Grafik Eşleme (EBGM)

Elastik Demet Grafik Eşleme (Elastic Bunch Graph Matching – EBGM) yöntemi, tek bir yüz görüntüsünden tanıma işlemini gerçekleştirmek amacıyla Gabor dalgacık (wavelet) özneliklerini ve grafik tabanlı eşleme yaklaşımını bir araya getirmektedir (Daugman, 1988; Verma ve Khunteta, 2018; Mehta ve Jadhav, 2017).

Yöntemin performansı, FERET ve Bochum yüz veritabanları üzerinde yürütülen deneylerle değerlendirilmiştir (Verma ve Khunteta, 2018). FERET veri setinde; nötr frontal, farklı ifadeli frontal, yarı profil (sağ/sol) ve tam profil (sağ/sol) pozları kullanılmıştır. Frontal pozlar arasında tanıma oranı yaklaşık %100 seviyesinde elde edilmiş, bu yüksek başarı, veri setindeki sınırlı varyasyonla ilişkilendirilmiştir. Öte yandan, sağ ve sol tam profillerde tanıma oranı %84, yarı profillerde ise %57 olarak ölçülmüştür. Bu düşüş, hem yüzlerin doğal asimetrisi hem de poz açılarındaki kontrolsüzlüklerden kaynaklanmaktadır.

Bochum veri seti üzerinde gerçekleştirilen ikinci deneyde ise farklı ifadeli frontal pozlar ile 11° ile 22° arasındaki dönüş açılarındaki yüz pozları değerlendirmeye alınmıştır. Bu deneyde sırasıyla %91, %94 ve %88 oranlarında tanıma başarısı elde edilmiştir. FERET sonuçları ile karşılaştırıldığında, Bochum veri setindeki daha çeşitli yüz ifadeleri nedeniyle, farklı ifadeli frontal pozlardaki tanıma oranları görece daha düşük kalmıştır. Genel olarak EBGM yöntemi, aynı pozdaki yüzler arasında oldukça yüksek tanıma

doğruluğu sunmakta; ancak özellikle derinlik eksenindeki rotasyon gibi açısal değişimlere karşı sınırlı bir dayanıklılık sergilemektedir.

2.1.5. Bağımsız Bileşenler Analizi (ICA)

Bağımsız Bileşenler Analizi (Independent Component Analysis - ICA), geleneksel PCA yöntemine kıyasla daha yüksek ayrıştırma gücüne sahip bir öznelik çıkarım yöntemidir. Özellikle pikseller arasındaki karmaşık ilişkileri modelleyerek yüz tanıma performansını artırır (Bell ve Sejnowski, 1995; Bartlett, 2007).

(Borade vd. 2015) tarafından ORL veri seti üzerinde gerçekleştirilen deneyde, ICA ile elde edilen öznelik sayısı arttıkça tanıma başarımının da yükseldiği gösterilmiştir. Özellikle 20–50 bileşen arasında %85'e varan doğruluk oranı elde edilmiş; 50 bileşenden sonra bu başarı plato çizmiştir.

(Bartlett vd. 2002) tarafından FERET veri seti üzerinde yürütülen başka bir çalışmada ise ICA yöntemleri, farklı ifade ve gün kombinasyonlarında PCA'ya göre daha yüksek ve kararlı doğruluklar üretmiştir. En başarılı sonuç, %91 başlangıç ve %82 tutarlılık oranı ile "ICA Combined" yöntemine ait olmuştur. Bu sonuçlar, ICA'nın özellikle değişken yüz ifadeleri ve zaman farkları gibi zorlu koşullarda PCA'ya göre daha dayanıklı ve etkili olduğunu ortaya koymaktadır.

2.1.6. HOG – EBGM Tabanlı Yüz Tanıma

Zamanla artan hesaplama gücü sayesinde yüz tanıma sistemleri daha karmaşık ve etkili yöntemlerle geliştirilebilmiştir. Bu bağlamda, Elastik Demet Grafik Eşleme (Elastic Bunch Graph Matching – EBGM) yöntemi, tek bir yüz görüntüsünden tanıma gerçekleştirmek amacıyla Gabor dalgacık özneliklerini ve grafik tabanlı eşleme yapısını kullanmaktadır. Bu yöntem, Yönlendirilmiş Gradyan Histogramları (Histogram of Oriented Gradients – HOG) tanımlayıcılarının entegre edilmesiyle hem doğruluk hem de hesaplama verimliliği artırılmıştır.

Albiol ve arkadaşlarının FERET veri seti üzerindeki çalışmasında yedi yöntem karşılaştırılmış; HOG–EBGM yöntemi fafb, fafc, dup1 ve dup2 alt testlerinde sırasıyla %95,5, %81,9, %60,1 ve %55,6 doğruluk oranları ile en yüksek başarıyı göstermiştir. Bu sonuçlar, HOG’un aydınlatma ve poz farklılıklarına karşı dayanıklılığı ile EBGM’in esnek yüz grafiği temsillerinin birleşiminin etkili olduğunu ortaya koymaktadır (Albiol vd., 2008).

2.1.7. Seyrek Temsil Tabanlı Sınıflandırma (SRC)

(Wang vd., 2013) gerçekleştirdiği çalışmada, yüz tanıma sistemlerinin doğruluğunu artırmak amacıyla Seyrek Temsil Sınıflandırması (Sparse Representation-based Classification – SRC) algoritması, kısıtlı örnekleme ve yüz hizalama teknikleri ile entegre edilmiştir. Önerilen yaklaşım, yüz görüntüsündeki temel anahtar noktalardan hem dokusal hem de biçimsel öznitelikleri eşzamanlı olarak çıkararak güçlü ve ayrıştırıcı bir öznitelik kümesi oluşturmaktadır. Bu yöntem, AR veri setinde %99,52 ve CAS-PEAL veri setinde %99,54 doğruluk oranlarıyla test edilmiş; dokusal ve geometrik bilgilerin birlikte kullanılmasının yüz tanıma başarımını önemli ölçüde artırdığı gösterilmiştir.

2.1.8. HOG ve DMMA Tabanlı Tek Örnekli Yüz Tanıma

Yüz tanıma alanında gerçekleştirilen önemli çalışmalardan biri, FERET veri seti üzerinde uygulanmıştır. Toplamda 1565 kişiye ait 13.539 yüz görüntüsü içeren bu veri tabanından rastgele seçilen 200 kişiye ait, farklı yüz ifadeleri, aydınlatma koşulları ve bakış açılarını yansıtan yedişer görüntü kullanılmış; tüm görseller 60×60 piksel boyutuna normalize edilmiştir.

Bu çalışmada önerilen HOG–DMMA yöntemi, tanıma başarımı açısından DMMA, HOG, MFA (Yan vd., 2007), LE (Belkin ve Niyogi, 2003) ve ISOMAP (Tenenbaum vd., 2000) gibi geleneksel boyut indirgeme yöntemleri ile karşılaştırılmıştır. Yüz görüntüleri 10×10 piksellik yamalara bölünerek HOG öznitelikleri çıkarılmış, ardından bu özniteliklere Ayrımsal Çoklu Manifold Analizi (Discriminant Multi-Manifold Analysis – DMMA) uygulanmıştır. Modelin eğitimi için bir alt küme, test işlemi için ise yedi alt küme kullanılmıştır.

Elde edilen sonuçlar, HOG–DMMA algoritmasının özellikle yüz pozisyonu ve aydınlatma değişimlerine karşı yüksek dayanıklılık gösterdiğini ve diğer yöntemlere kıyasla daha düşük işlem süresine sahip olduğunu ortaya koymaktadır. Ortalama tanıma süresi 0.385 saniye olan bu yöntem, DMMA’ya göre yaklaşık altıda bir daha hızlı çalışmakta ve genel olarak daha yüksek doğruluk oranları sunmaktadır. Bu bulgular, HOG–DMMA’nın hem sınıflandırma performansı hem de hesaplama verimliliği açısından literatürdeki pek çok yöntemle üstünlük sağladığını göstermektedir (Ji vd., 2016).

2.1.9. HOG-PCA ve Morfolojik-Aritmetik İşlemlerle Pseudo-Sketch Tabanlı Yüz Tanıma

Bu yöntem, eğitim verilerine ihtiyaç duymaksızın yüz fotoğraflarını sahte eskizlere (pseudo-sketch) dönüştürmeye dayanmaktadır. Yüzün belirgin yapısal özelliklerini ortaya çıkarmak için basit matematiksel ve morfolojik işlemler uygulanmakta; böylece elde edilen sahte eskiz görüntüleri, adli eskizlerle eşleştirilmek üzere Histogram of Oriented Gradients (HOG) ve Temel Bileşenler Analizi (PCA) algoritmalarının birleşimi olan HOG–PCA yöntemiyle.

Yöntem kapsamında, yüz görüntüsü örtüşen yama bölgelere ayrılarak HOG öznitelikleri çıkarılmakta; ardından bu özniteliklerin boyutu PCA ile azaltılmaktadır. Elde edilen özellik vektörleri, kosinüs benzerliği ölçütü ile değerlendirilmekte ve En Yakın Komşu Sınıflandırıcısı (Nearest Neighbor Classifier – NNC) yardımıyla eşleştirme yapılmaktadır (Struc ve Pavešić, 2009; Struc ve Pavešić, 2010).

Abduljalil Radman ve Shahrel Azmin Suandi tarafından yürütülen çalışmada (Radman ve Suandi, 2018), söz konusu yöntem CUHK ve AR yüz veri setleri üzerinde test edilmiştir. CUHK veri setinde %100, AR veri setinde ise %99 doğruluk oranı elde edilmiştir. Bu yüksek başarı, yöntemin farklı aydınlatma ve açı değişikliklerine karşı oldukça dayanıklı olduğunu göstermektedir.

Aynı çalışmada HOG–PCA yaklaşımı, diğer geleneksel yöntemlerle de karşılaştırılmıştır. Özellikle bulanık yüzlerin tanınmasında kullanılan Yerel Faz Kantifikasyonu (Local

Phase Quantization – LPQ) yöntemi (Ahonen vd., 2008) ile çekirdek tabanlı yüz tanıma tekniklerinden çekirdek Eigenface ve çekirdek Fisherface yöntemleri (Yang, 2002) karşısında da daha yüksek doğruluk ve daha kısa işlem süresiyle üstünlük sağlamıştır.

2.1.10. Üçgensel Bulanık Küme ve LDP ile Dalgacık Tabanlı Yüz Tanıma

Yüz tanıma teknikleri, sınıflandırma aşamasında başlangıçta geleneksel görüntü işleme ve öznitelik tabanlı yöntemlere dayanıyordu. Bu yaklaşımın ötesinde, Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform – DWT), Üçgen Bulanık Dönüşüm (Triangular Fuzzy Transformation) ve Yerel Çapraz Desen (Local Cross Pattern – LCP) yaklaşımlarını birleştiren yenilikçi bir model önerilmiştir. Önerilen yöntemde, yüz görüntüsüne iki boyutlu DWT uygulanarak yapısal açıdan en kritik bilgileri içeren düşük frekanslı LL alt bandı elde edilmektedir. Bu alt banda uygulanan üçgen bulanık dönüşüm sonucunda A, B ve C olmak üzere üç ayrı alt görüntü oluşturulmakta; özellikle B alt görüntüsünden, düşey (VLCP) ve yatay (HLCP) yönlerde LCP betimleyicileri aracılığıyla yüzün mekânsal ve detaylı öznitelikleri çıkarılmaktadır. Elde edilen öznitelik vektörleri, Doğrusal Ayırıcı Analiz (LDA), Kuadratik Ayırıcı Analiz (QDA), Çekirdek Tabanlı Destek Vektör Makineleri (Kernel SVM) ve En Yakın Komşu (KNN) gibi çeşitli sınıflandırma algoritmalarıyla analiz edilmiştir (Abuzneid ve Mahmood, 2018; Beyer vd., 1999).

Tuncer, Doğan ve Avcı'nın yürüttüğü çalışmada, bu sistem AT&T, CIE, Face94 ve FERET veri setleri üzerinde sırasıyla %97,3; %100; %100 ve %96,3 doğruluk oranları ile yüksek tanıma başarımı göstermiştir (Tuncer vd, 2019). Bu sonuçlar, DWT tabanlı bulanık dönüşüm ile LCP betimleyicilerinin birleşiminin, aydınlatma değişikliklerine ve yüz detaylarındaki varyasyonlara karşı etkili ve dayanıklı bir çözüm sunduğunu ortaya koymaktadır.

2.1.11. HOG–LDB ve SVDL Kullanarak Yüz Tanıma

Wang ve arkadaşlarının çalışmasında (Wang vd., 2019), kişi başına yalnızca bir örnek görüntü kullanılarak yüz tanıma gerçekleştirilmiştir. Bu amaçla, Yönlendirilmiş Gradyan

Histogramları (HOG) ile Yerel Fark İkili (Local Difference Binary – LDB) öznitelik çıkarımı yöntemi, Seyrek Varyasyon Sözlüğü Öğrenme (Sparse Variation Dictionary Learning – SVDL) yaklaşımıyla birlikte uygulanmıştır. İlk aşamada HOG–LDB öznitelikleri, yüz görüntülerindeki kenar ve yerel desen bilgilerini detaylı şekilde temsil ederken; sonraki aşamada SVDL algoritması eğitim verilerinden seyrek varyasyon sözlüğü oluşturmuştur. Bu yapı, aydınlatma, poz ve yüz ifadeleri gibi değişken koşullara karşı yüksek dayanıklılık sağlamaktadır.

AR, Yale, Extended Yale B ve CMU-PIE veri setleri üzerinde gerçekleştirilen deneyler, önerilen yöntemin önceki yaklaşımlara göre daha yüksek doğruluk sağladığını göstermektedir. Özellikle Yale B veri setinde, HOG–LDB + SVDL birleşimi %98,6 doğruluk oranına ulaşırken; karşılaştırmalı olarak SVM %41,4, CRC %51,2, DMMA %61,7 ve SRC %49,2 doğruluk elde etmiştir. Bu sonuçlar, yöntemin üstün performansını açık biçimde ortaya koymaktadır.

2.1.12. HOG-ESR ve Paylaşılan Temsiller Topluluğu (ESR)

HOG ile genelleme hatasını azaltarak sınıflandırma doğruluğunu artırmayı amaçlayan Paylaşılan Temsiller Topluluğu (Ensembles with Shared Representations – ESR) yöntemi, HOG öznitelikleriyle birleştirilerek HOG–ESRs adlı yeni bir yüz duygu tanıma algoritması geliştirilmiştir. Bu yöntem özellikle değişken aydınlatma koşullarında klasik yaklaşımlara göre daha üstün performans sergilemeyi hedeflemektedir.

Zhong, Yuanchang ve arkadaşlarının gerçekleştirdiği çalışmada (Zhong, Yuanchang vd., 2021), FER+ yüz ifadesi veri seti üzerinde HOG–ESRs yöntemi hem öznitelik çıkarımı hem de genel doğruluk açısından yüksek başarı göstermiştir. Model, tüm eğitim verisiyle eğitilmiş ve hiperparametreler çapraz doğrulama yoluyla optimize edilmiştir. Tek bir ağ 140.802 örnekle $\%85,3 \pm 2,1$ doğruluk sağlarken, klasik topluluk yöntemi 560.328 örnekle bu oranı $\%89,1 \pm 1,5$ 'e çıkarmıştır.

Özellikle HOG–ESR-4 Lvl.4 konfigürasyonu, yalnızca 370.411 örnekle $\%89,3 \pm 1,1$ doğruluk elde ederek daha az veriyle daha yüksek verimlilik sunmuştur. HOG–ESR-4

Lvl.5 ise 250.005 örnekle $\%88,4 \pm 3,5$ doğrulukla, örnek sayısı azalsa dahi güçlü ve dengeli sonuçlar sağlamaya devam etmiştir. Bu veriler, Lvl.4 yapılandırmasının örnek–doğruluk dengesi açısından en verimli çözüm olduğunu ortaya koymaktadır.

2.1.13. BPSO ve SVM Tabanlı Derin Özellik Seçimi ile Yüz Duygu Tanıma

Duygu sınıflandırmasının doğruluk ve hızını artırmak amacıyla yapay zekâ teknikleri kullanılarak üç aşamalı bir yüz duygu tanıma sistemi geliştirilmiştir. Donuk ve arkadaşlarının çalışmasında (2021), ilk aşamada FER+ veri seti üzerinde yüz görüntülerinden 128 öznitelik çıkarmak amacıyla bir Konvolüsyonel Sinir Ağı (CNN) eğitilmiştir. İkinci aşamada, sınıflandırma performansına en fazla katkı sağlayan öznitelikleri belirlemek için İkili Parçacık Sürü Optimizasyonu (Binary Particle Swarm Optimization – BPSO) algoritması kullanılmıştır. Son aşamada ise seçilen öznitelikler Destek Vektör Makineleri (SVM) ile sınıflandırılmıştır (Donuk vd., 2021).

Elde edilen bulgular, BPSO ile SVM’nin birleştirilmesinin, yalnızca SVM kullanımına kıyasla hem sınıflandırma doğruluğunu hem de işlem hızını artırdığını ve nihai doğruluk oranının $\%85,74$ olduğunu göstermektedir. Çalışma, önerilen sistemin girdi öznitelik sayısını azaltarak sınıflandırma performansını optimize ettiğini ve FER+ veri seti üzerinde duygu tanıma sistemlerinin etkinliğini anlamlı biçimde artırdığını ortaya koymaktadır.

3. MATERYAL ve METOT

3.1. Yazılım

Projemiz bütünü yazılıma dayanıyor bu yüzden kullanılan yazılım olanakları çok önem taşır, yazılım olanakları şöyle sınıflayabiliriz:

1. Kullanılan programlama dili.
2. Kullanılan ara yüzü.
3. Kullanılan kütüphaneler.
4. Kullanılan yazılım yöntemler.

3.1.1. Kullanılan Programlama Dili ve Ara Yüzü

Bu projede kullanılan programlama dili Python'dur. Python, dünya genelinde en yaygın programlama dillerinden biridir. Görüntü işleme, yapay zekâ ve çeşitli uygulama geliştirme alanlarında oldukça başarılıdır. Bunun başlıca nedenleri; geniş kütüphane desteğine sahip olması, sözdiziminin insan diline yakın ve anlaşılır olması, nesne tabanlı yapıda çalışması ve kütüphanelerinin açık kaynaklı olup sürekli geliştirilmesidir.

Bu programlama dili üzerinde çalışmak için birden fazla geliştirme ortamı sunulmakta olup bu projede geliştirme ortamı olarak Google tarafından sunulan Colab arayüzü kullanılmıştır. Bu ara yüz CPU'lar, GPU'lar ve TPU'lar kullanarak yapay zekâ modellerinin eğitilmesi için ücretsiz ve çevrimiçi olanaklar sağlar.

Google Colab'ın ana özellikleri aşağıdaki gibi sıralanabilir:

1. Ücretsiz Bulut Tabanlı Hizmet: GPU ve TPU desteği sunar (ücretsiz katmanda sınırlı kaynak), Tarayıcı üzerinden erişim, kurulum gerektirmez.
2. Kütüphane desteği: Google Colab, veri analizi ve makine öğrenimi için gerekli popüler kütüphaneleri (NumPy, Pandas, Matplotlib, TensorFlow gibi) ön yüklü olarak sunar. Bu kütüphaneleri kullanmak için herhangi bir kurulum

gerekmeyp, doğrudan import komutuyla projenize dahil edelabilir Ek Paketler ise !pip install ile kolayca yüklenebilir.

3. Kolaboratif Çalışma: Gerçek zamanlı Google Docs benzeri iş birliği, GitHub entegrasyonu ve paylaşılabilir bağlantılar.
4. Bulut Depolama Entegrasyonu: Google Drive bağlantısı (from google.colab import drive), BigQuery, Google Sheets ve diğer veri kaynaklarına erişim.

3.1.2. Kullanılan Kütüphaneler

Python programlama dili, geniş kütüphane desteği sayesinde birçok alanda tercih edilmektedir. Bu tez çalışması kapsamında toplam 13 adet Python kütüphanesi kullanılmıştır. Google Colab platformu çevrimiçi bir arayüz sunduğu için bu kütüphanelerin bilgisayara indirilmesine gerek yoktur; yalnızca kod içerisine dahil edilmeleri yeterlidir. Çünkü Colab, birçok kütüphaneyi belleğinde hazır olarak bulundurmaktadır. Her bir kütüphane, sınıflar (class) ve fonksiyonlar (function) içermekte olup, bu yapılar aracılığıyla kütüphanelerde tanımlı metotlardan faydalanmak mümkündür.

3.1.2.1. Sklearn Kütüphanesi

Scikit-learn, Python dilinde makine öğrenmesi ve veri madenciliği uygulamaları için yaygın olarak kullanılan bir kütüphanedir. Bu kütüphane, veriyi işleme, modelleme, değerlendirme ve optimizasyon için birçok araç sunar. Kütüphane, çeşitli makine öğrenmesi algoritmalarını (sınıflandırma, regresyon, kümeleme vb.) ve model değerlendirme metriklerini içerir.

Bu projede Sklearn kütüphanesinden 5 farklı fonksiyon kullanılmıştır, her fonksiyonun projede kullanılma amacı:

1. `Precision_recall_fscore_support`: Bu fonksiyon, sınıflandırma problemlerinde modelin performansını değerlendirmek için kullanılır. Precision (kesinlik), recall (duyarlılık), F-score ve destek (support) metriklerini hesaplar projede Bu fonksiyon, modelin doğruluğunu değerlendirmek için kullanılabilir.
2. `Train_test_split`: Veri kümesini eğitim ve test kümelerine ayırmak için kullanılır. Bu, modelin doğruluğunu test etmek için gereklidir.
3. `Class_weight`: `class_weight` fonksiyonu, dengesiz veri setlerinde sınıfların ağırlıklarını hesaplamak için kullanılır. Bu, her sınıfın model üzerinde eşit şekilde etkili olmasını sağlamak için önemlidir.
4. `Classification_report`: Modelin performansını gösteren metrikleri raporlar (precision, recall, F-score, support).
5. `Confusion_matrix`: Modelin tahminlerinin doğruluğunu ölçmek için karışıklık matrisi oluşturur.

3.1.2.2. Keras Kütüphanesi

Keras Kütüphanesi, TensorFlow üzerine inşa edilmiş yüksek seviyeli bir derin öğrenme API'sidir. callbacks sınıfı, modelin eğitimi sırasında belirli olayları izlemek ve tepki vermek için kullanılır. Eğitimi denetlemek ve iyileştirmek için kullanabileceğiniz birçok callback vardır.

Projemizde keras kütüphanesinden kullanıldığı fonksiyonların ve kullanımları aşağıdaki gibi sıralandı:

1. `ModelCheckpoint`: Modelin her epoch'ta kaydedilmesini sağlar ve en iyi doğruluk gösteren modelin kaydedilmesini sağlar.
2. Keras backend (özellikle TensorFlow), modelin eğitimi sırasında bellek yönetimi ve modelin temizlenmesi gibi işlemleri yönetir.

3. Layers: Keras'ta derin öğrenme modelleri oluştururken kullanılan katmanlar (Dense, Conv2D, Dropout, Input gibi) bu modülden gelir.
4. Model: Keras'ta derin öğrenme modelini tanımlamak için kullanılan sınıftır, modelin yapı taşlarını (giriş ve çıkış katmanları) tanımlamak için kullanılır.
5. ReduceLROnPlateau: Eğitim sırasında doğrulama kaybı (loss) iyileşmediğinde öğrenme hızını (learning rate) azaltarak modelin daha iyi öğrenmesini sağlar.
6. EarlyStopping: Eğitim sırasında modelin aşırı öğrenmesini (overfitting) engellemek için kullanılır. Eğitim, modelin doğrulama kaybı iyileşmezse durdurulur.

3.1.2.3. Imblearn Kütüphanesi

Imblearn, dengesiz veri setlerinde makine öğrenmesi uygulamaları için kullanılan bir Python kütüphanesidir. Dengesiz veri setleri, bazı sınıfların diğerlerinden çok daha fazla olduğu durumlardır. Bu kütüphane, dengesiz veri setlerini işlemek için çeşitli araçlar sunar.

Projede `classification_report_imbalanced` fonksiyonu kullanıldı ve bu fonksiyon `classification_report`'ın dengesiz veri setlerinde daha doğru bir şekilde çalışmasını sağlayan bir fonksiyon. Bu fonksiyon, özellikle düşük temsil edilen sınıflar için daha iyi sonuçlar elde edilmesini sağlar.

3.1.2.4. TF (Tensorflow) Kütüphanesi

TF kütüphanesi, Google tarafından geliştirilen açık kaynaklı bir makine öğrenmesi ve derin öğrenme kütüphanesidir. Keras, TensorFlow için yüksek seviyeli bir API olarak çalışır ve derin öğrenme modelinin kolayca inşa edilmesini sağlar. Projede `to_categorical` TF kütüphanesinden bu fonksiyonu kullanıldı, bu fonksiyon sınıf etiketlerini (örneğin, [0, 1, 2]) one-hot encoding formatına (örneğin, [1, 0, 0]) dönüştürür.

3.1.2.5. matplotlib.pyplot Kütüphanesi

Python'da veri görselleştirmeleri yapmak için yaygın olarak kullanılan bir kütüphanedir. Özellikle grafikler, çizimler ve görsel veri sunumları oluşturmak için kullanılır. pyplot modülü, Matlab tarzı bir API sunar ve veri görselleştirme sürecini oldukça basitleştirir.

Projede Modelin eğitim süreci sırasında doğruluk ve kayıp değerlerini görselleştirmek için kullanılır. Eğitim ve doğrulama doğruluğu ve kaybı grafik olarak gösterilir.

3.1.2.6. Pd (Pandas) Kütüphanesi

Python dilinde veri analizi ve işleme işlemleri için en yaygın kullanılan açık kaynaklı kütüphanedir. Özellikle büyük veri setleriyle çalışırken, veri manipülasyonu ve analizi yapmak için çok güçlü araçlar sağlar. Pandas, veri analistleri ve bilim insanları arasında popülerdir, çünkü verileri hızlı bir şekilde düzenlemeye, analiz etmeye ve görselleştirmeye yardımcı olur.

3.1.2.7. NumPy Kütüphanesi

Python'da temel liste yapıları veri işleme için kullanılabilse de, performans açısından yetersiz kalabilmektedir. NumPy kütüphanesi, bu sorunu çözmek için geliştirilmiş olup, standart Python listelerine kıyasla 50 kat daha hızlı çalışabilen optimize edilmiş dizi (array) yapıları sunmaktadır.

Projede NumPy Verilerin işlenmesi, matris işlemleri ve numpy fonksiyonları için kullanıldı.

3.1.2.8. Scipy Kütüphanesi

SciPy, bilimsel hesaplamalar için kullanılan bir Python kütüphanesidir, veri manipülasyonu, görüntü işleme gibi işlemler için projede kullanılır ve bu kütüphanesinden ndimage fonksiyonu kullanıldı bu fonksiyon veri arttırma işlemleri (dönme, kaydırma, zoom) için kullanıldı.

3.1.2.9. Skimage Kütüphanesi

Python'da görüntü işleme için özel olarak geliştirilmiş bir kütüphanedir. NumPy dizileri üzerinde çalışarak tıbbi görüntüler, fotoğraf analizi ve bilgisayarlı görü uygulamalarını kolaylaştırır.

Scikit-learn (ya da kısaca sklearn), Python için açık kaynaklı bir makine öğrenmesi kütüphanesidir. Scikit-learn, hem denetimli (supervised) hem de denetimsiz (unsupervised) öğrenme algoritmaları sunar ve verilerin işlenmesi, modellenmesi ve değerlendirilmesi için çok sayıda araç sağlar. Bu kütüphane, sınıflandırma, regresyon, kümeleme (clustering), boyut indirgeme (dimensionality reduction), model seçimi ve değerlendirme gibi pek çok görev için kullanılır.

Scikit-learn, bu kodda veri işleme, model değerlendirme ve kendi başına performans metriklerinin hesaplanması için kullanılmıştır. Bu kütüphane, özellikle modelin doğruluğunu ve başarı metriklerini değerlendirmek için büyük rol oynamaktadır.

3.1.2.10. OpenCV Kütüphanesi

Bilgisayarla görme ve görüntü işleme üzerine çalışan açık kaynaklı bir kütüphanedir. Hem akademik hem de endüstriyel alanda geniş bir kullanım alanına sahiptir. C++ dilinde yazılmış olsa da, Python gibi diller için de güçlü bağlayıcılar (bindings) sunar. OpenCV, görüntü işleme, video analiz, makine öğrenimi ve bilgisayarla görme uygulamalarını geliştirmek için kullanılan en popüler kütüphanelerden biridir.

3.1.2.11. Os Kütüphanesi

Python'un os (operating system) kütüphanesi, işletim sistemi ile etkileşimde bulunmak için kullanılan bir modüldür. Dosya ve izin işlemleri, sistem çevre değişkenlerini yönetme, işlem yönetimi gibi işlemleri kolaylaştıran bir dizi fonksiyon sağlar.

3.1.3. Yazılımda Kullanılan Yöntemler

Projede kullandığımız modelleri daha iyi bir şekilde oluşturmak için ve kodların kolay anlaşılacak şekilde olması, yazılımın performansı artırmak ve koda değişiklikler yapmak istendiğinde kolaylık sağlaması için proje yazılımı hazırlandı.

Bahsettiğimiz özellikleri gerçekleştirmek için yazılımda gerekli yöntemler kullanıldı bunların birincisi -Nesne Yönelmeli Programlama- ve ikincisi de -Fonksiyonlar- kullanıldı.

3.1.3.1. Fonksiyonlar

Yazılım kısmında kullanılan yöntemlerden biri fonksiyonlardır, yazılımda sıkça kullanılan komutlar ve işlemler fonksiyon olarak tanımlamak ve ihtiyaç duyulduğunda o fonksiyonu çağırmak yazılım daha kolay anlaşılması ve tekrarlı kodlar yazılmaması ve kod uzunluğunun kısaltılması ve karmaşık olmaması için bireysel fonksiyonlar kullanıldı.

3.2. Kullanılan Veri Seti

Çalışmada, daha önce farklı araştırmalarda da kullanılan 5 farklı hazır yüz tanıma veri seti kullanılmıştır. Bu bölümde verisetleri detaylı şekilde açıklanacaktır.

3.2.1. Feret Veri Seti

FERET Yüz tanıma teknolojisi (Facial Recognition Technology) veri seti, yüz tanıma teknolojilerinde yaygın olarak kullanılan bir veritabanıdır. FERET, ABD Savunma Bakanlığı'nın bir parçası olarak, özellikle yüz tanıma algoritmalarının performansını değerlendirmek amacıyla oluşturulmuştur (Phillips vd., 1996 ve Rauss vd., 1996).

Bu veri seti, farklı ışıklandırma koşulları (gün ışığı, yapay ışık, düşük ışık gibi), çeşitli baş pozisyonları (yüz yukarı, aşağı, sol, sağ gibi) ve yüz ifadeleri (mutluluk, öfke, nötr ifadeler), ve genellikle farklı etnik kökenlere, yaşlara ve cinsiyetlere sahip bireylerden

alınan yüz görüntülerinden oluşur ve çeşitli aydınlatma koşullarında ve farklı bakış açılarıyla çekilmiştir. Bu çeşitlilik, yüz tanıma algoritmalarının gerçek dünya koşullarına uyum sağlayabilmesi için önemlidir ve yüz tanıma algoritmalarının doğruluğunu test etmek için standart bir veri seti olarak kullanılmaktadır. Feret veri seti 194 sınıf içerir (Araştırmadaki "sınıf" kavramı, yüz tanıma bağlamında bir kişiyi temsil eden kategori anlamına gelir) ve her sınıfta örnek sayısı 10 fotoğraf bulunmaktadır. Veri setinden örnek fotoğraflar Şekil 3.1'de gösterilmiştir.



Şekil 3.1 Feret veri seti örnek görüntüler

3.2.2. Georgia Veri Seti

Georgia Tech Face Database (GTDB) veya kısaca Georgia veri seti, yüz tanıma alanında sıklıkla kullanılan akademik veri kümelerinden biridir. Georgia Institute of Technology tarafından oluşturulmuş bir yüz görüntüleri veri setidir (1). Bu veri seti, özellikle yüz tanıma ve yüz tespiti (face detection & recognition) algoritmalarının geliştirilmesi ve test edilmesi için hazırlanmıştır bu veri seti toplam sınıf sayısı: 50 farklı sınıf içerir ve her

sınıf içinde görüntü sayısı her sınıftan 15 farklı görüntü – toplam 750 yüz görüntüsü içerir.

Bu görüntüler farklı pozlar içerir her yüz farklı yönleri (örneğin sola, sağa bakma), ifadeler (gülümseme, nötr), farklı arka planlar var. Ve bu veri seti doğal ortam görüntüler sınıf ortamı gibi doğal arka planlarda çekilmiş, yani stüdyo ortamından ziyade gerçek koşulları yansıtır Şekil 3.2'de bu veri setin örnek fotoğrafları gösterildi.



Şekil 3.2 Georgia veri seti örnek görüntüler

3.2.3. Orl Veri Seti

ORL Veri Seti (ORL Database of Faces), yüz tanıma algoritmalarını test etmek amacıyla hazırlanmış, bilgisayarla görü araştırmalarında sıkça kullanılan klasik bir veri kümesidir. ORL veri seti, İngiltere'deki Olivetti Research Laboratory (ORL) tarafından Cambridge Üniversitesi iş birliğiyle oluşturulmuştur (Samaria ve Harter, 1994).

Bu veri setinde her kiři farklı pozlar, ifadeler (gölümseme, ciddi yüz) ve aydınlatma koşulları altında çekilmiştir. Bazı görüntülerde gözlük vardır, bazılarında yoktur. Arka plan basittir ve sabittir, bu sayede modelin dikkatini sadece yüze vermesi sağlanır ve tüm fotoğraflar aynı kamera açısıyla ve durağan bir arka planda çekilmiştir.

Bu veri seti toplam sınıf sayısı: 40 farklı kişidir her kişiden 10 farklı yüz görüntüsü vardır toplam görüntü 400 adet gri tonlamalı (Griseviye) yüz görüntüsü sahiptir. Şekil 3.3'te Orl veri setinden örnek görüntüler gösterilmiştir.



Şekil 3.3 Orl veri seti örnek görüntüler

3.2.4. Put Veri Seti

PUT (Poznań University of Technology) Yüz Veritabanı, yüz tanıma algoritmalarını değerlendirmek amacıyla oluşturulmuş, kontrollü koşullar altında çekilmiş yüksek kaliteli yüz görüntülerinden oluşan akademik bir veri setidir. PUT veri seti, Polonya'daki Poznań Teknoloji Üniversitesi tarafından geliştirilmiştir (Kaşinski vd., 2008). Bu veri seti, yüz tanıma ve yüz analizi üzerine çalışan araştırmacılar için önemli bir referans

niteliği taşır; özellikle yüz yönelimi (pose), aydınlatma (illumination) ve yüz ifadeleri (expressions) gibi değişkenleri içermesiyle dikkat çeker.

Veri seti, farklı yaş gruplarından ve cinsiyetlerden seçilen 100 kişiden oluşan bir örneklem üzerinde toplanmıştır. Görüntüler, dokuz ayrı kameranın farklı açılara (sağ, sol, üst, alt, çapraz vb.) yerleştirildiği bir düzenekte; sabit bir arka plan ve laboratuvar ortamında kontrollü aydınlatma koşulları altında çekilmiştir. Ayrıca, veri setinde gözlük takma durumu, gülümseme ve ağız kapalı/açık gibi yüz ifadeleri yer almakta; yüz ifadeleri ve bakış yönleri kontrollü olarak değiştirilerek, her kişiden farklı pozisyonlarda yüz görüntüleri elde edilmiştir. Bu sayede akademik çalışmalar hem poz hem de ifade varyasyonlarına karşı dayanıklı modeller geliştirebilmektedir. Veri seti toplamda 100 sınıf içerir ve her sınıfta 10 görüntü bulunmaktadır. Şekil 3.4'te PUT veri setinden örnek görüntüler verilmiştir.



Şekil 3.4 Put veri seti örnek görüntüler

3.2.5. Yale Veri Seti

Yale Yüz Veri Seti (Yale Face Database), yüz tanıma araştırmaları için sıklıkla kullanılan klasik bir veri kümesidir. Bu veri seti, Yale Üniversitesi'nde Center for Computational Vision and Control tarafından oluşturulmuştur (Georghiades vd., 2001). Temel amacı, farklı yüz ifadeleri, pozlar ve ışıklandırma koşulları altında yüz tanıma algoritmalarının

başarımını değerlendirmek. Yale yüz veri seti, kontrollü bir ortamda çekilen yüz görüntülerinden oluşur. Her katılımcının yüzü, farklı yüz ifadeleri ve aydınlatma durumlarıyla kaydedilmiştir.

Yale veri seti toplamda 39 sınıftır ve her sınıfın örnek sayısı toplamı 60-65 arasındadır.

Şekil 3.5'te Yale veri setinden örnek görüntüler verilmiştir.



Şekil 3.5 Yale veri seti örnek görüntüler

3.2.6. Veri Setlerinin Karşılaştırması

FERET veri seti, yüksek sınıf sayısı ve çeşitli poz, ifade ve ışık koşulları sayesinde algoritmaların geniş varyasyonlara karşı performansını ölçmekte oldukça etkilidir. Buna karşın, Georgia veri seti daha az sayıda sınıfa sahip olmasına rağmen, doğal ortamlarda çekilmiş görüntülerle gerçek yaşam koşullarını daha iyi yansıtır.

ORL veri seti ise sabit arka plan ve kontrollü çekim koşulları sayesinde temel yüz tanıma algoritmalarının eğitimi ve testinde tercih edilen klasik bir veri setidir. PUT veri seti, çoklu kamera açılarında ve laboratuvar koşullarında çekilen yüksek kaliteli görüntülerle, yönelim, ifade ve ışık gibi değişkenlerin etkisini analiz etmede oldukça kullanışlıdır. Son olarak Yale veri seti, ifade ve ışık değişkenliği açısından zengin yapısıyla, özellikle yüz

ifadelerinin sınıflandırılması gibi uygulamalarda güçlü bir test zemini sunar. Bu farklılıklar, her veri setini belirli araştırma amaçları için daha uygun hale getirmektedir. Algoritmanın test edileceği senaryoya bağlı olarak veri seti seçimi büyük önem taşır. Örnek sayısı açısından karşılaştırma yapsak yüz tanıma veri setleri, içerdiği toplam görüntü sayısı, algoritmaların öğrenme kapasitesi ve genelleme yeteneği üzerinde doğrudan etkilidir. Bu bağlamda incelendiğinde, Yale veri seti, her bir sınıf için yaklaşık 60–65 görüntü ile toplamda 2400’ün üzerinde görüntü sunarak örnek sayısı açısından en zengin veri setidir. Bunu, FERET veri seti yaklaşık 1940 görüntü ile takip eder, geniş sınıf sayısı ve çeşitli koşullarda çekilen görüntüler, algoritmaların farklı durumları öğrenmesini sağlar. PUT veri seti, 100 sınıftan oluşup her sınıfta 10 görüntü içerdiğinden toplamda 1000 örnek ile dengeli ve kontrollü bir yapı sunar.

Georgia veri seti, 50 sınıf ve her sınıf için 15 görüntü ile toplamda yaklaşık 750 görüntüye sahiptir. Gerçek yaşam ortamlarında çekildiği için sayıca sınırlı olsa da senaryo gerçekçiliği yüksektir. ORL veri seti ise 400 görüntü ile en az sayıda örneğe sahip olan veri setidir ve daha çok temel test senaryolarında tercih edilir.

Sonuç olarak, Yale ve FERET veri setleri yüksek örnek hacmiyle, özellikle derin öğrenme gibi veri gerektiren yöntemler için daha avantajlıdır, ORL ve Georgia gibi daha küçük veri setleri ise daha sınırlı ancak hedefe yönelik testler için uygun. Kullanılan veri setleri sınıf sayısı ve her sınıfın içinde içirildiği örnek sayısı ve her veri setinin koşullar ve Öne Çıkan Özellikler Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Yüz tanıma veri setlerinin karşılaştırması


Veri Setinin Adı	Sınıf Sayısı	Örnek Sayısı	Toplam Görüntü	Koşullar	Öne Çıkan Özellikler
Feret	194	10	1940	Farklı poz, ifade, ışık	Savunma projeleri için geliştirilmiş, geniş varyasyon
Georgia	50	15	750	Doğal ortam, çeşitli pozlar	Gerçekçi senaryolar, doğal arka plan
Orl	40	10	400	Sabit arka plan, kontrollü ortam	Temel algoritmalar için uygun, klasik veri seti

Çizelge 3.1 (Devam) Yüz tanıma veri setlerinin karşılaştırması

Veri Setinin Adı	Sınıf Sayısı	Örnek Sayısı	Toplam Görüntü	Koşullar	Öne Çıkan Özellikler
Put	100	10	1000	Çoklu kamera, kontrollü ışık	Yönelim, ifade ve ışık kontrolü
Yale	39	60-65	2452	Kontrollü ortam, farklı ifadeler	İfade ve ışık analizine uygun, yüksek örnek sayısı

3.3. Kullanılan Yöntem

Yüz tanıma sistemlerinde başarının temel unsurlarından biri, görüntüden anlamlı özniteliklerin çıkarılmasıdır. Bu çalışmada, Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP) ve Griseviye dönüşümü gibi geleneksel görüntü işleme yöntemleri kullanılarak yüz görüntülerinden öznitelikler elde edilmekte ve bu öznitelikler, derin öğrenme temelli bir modelin eğitimi için kullanılmaktadır. Model, bu öznitelikleri analiz ederek önemli yüz bilgilerini öğrenmekte ve sınıflandırma işlemini gerçekleştirmektedir.



Şekil 3.6 Yöntemin akış şeması


Projenin akış şeması Şekil 3.6’da gösterildiği gibi öncelikle görüntünün öznitelikleri (HOG, LBP, Griseviye) yöntemleri yardımıyla çıkarıldı daha sonrada çıkarılan öznitelikler derin öğrenme yardımıyla sınıflandırılmıştır.

Bu bölümde kullanılan her öznitelik çıkarma yöntemi ve derin öğrenme modelinin detaylı açıklaması yer almaktadır.

3.3.1. Yönlendirilmiş Gradyan Histogramları (HOG)

HOG, kenar yönelimlerini ve nesne şekillerini temsil etmede etkili bir öznitelik çıkarma yöntemidir (Dalal ve Triggs, 2005). Bu yöntemde, görüntü küçük hücrelere ayrılır ve her hücredeki gradyan yönelimleri histogramlar şeklinde hesaplanır. Özellikle göz, burun ve ağız çevresi gibi yüzün karakteristik bölgelerindeki yönelim farklılıkları, HOG özniteliklerini yüz tanıma uygulamalarında değerli kılar. Ayrıca, HOG algoritması aydınlatma değişimlerine karşı kısmen dayanıklıdır.

Şekil 3.7’de, HOG uygulanmadan önceki orijinal görüntü ile uygulama sonrasında elde edilen örnek yüz görüntüsü karşılaştırmalı olarak sunulmuştur. Görüldüğü üzere, HOG öznitelikleri sayesinde göz, burun, ağız, kulak ve kaş gibi yüz bölgeleri daha belirgin hale gelmekte ve bu karakteristiklerin yüz tanımda önemli rol oynadığı gözlemlenmektedir.




Şekil 3.7 HOG yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü

3.3.2. Yerel İkili Desen (LBP)

Yerel ikili desen (LBP), her pikselin 3×3 komşuluk bölgesindeki değerlere bakarak ikili bir kod oluşturur (Ojala vd., 1996). Bu yöntem, görüntüdeki mikro desenleri (texture) yakalamada etkilidir ve özellikle yüz bölgesindeki kırışıklıklar, gölgeler gibi ince yüzey yapılarının tanımlanmasında kullanılır. LBP’de, merkez pikselin değerinden büyük veya eşit olan komşu piksellere “1”, küçük olanlara “0” değeri atanır; bu ikili değerler bir LBP kodu oluşturur. Basit, hızlı ve düşük hesaplama maliyetine sahip olması nedeniyle, yaşlanma ve yüz ifadeleri gibi değişkenlere karşı dayanıklıdır.

Şekil 3.8’de, LBP uygulanmadan önceki orijinal görüntü ile uygulama sonrası elde edilen örnek yüz görüntüsü gösterilmiştir. Yüz ifadeleri (gülümseme, kaş çatma vb.) ve yaşlanmaya bağlı doku değişiklikleri çoğunlukla mikro yapıda ortaya çıktığından, LBP bu farklılıkları analiz edip ifade ve yaş değişimlerine karşı daha toleranslı sonuçlar verir. Şekilde de görüldüğü gibi, gülümseme LBP öznitelikleriyle başarıyla tespit edilmektedir.



Şekil 3.8 LBP yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü

3.3.3. Griseviye Dönüşümü

Griseviye yöntemi, renkli görüntüyü yalnızca ton bilgisini içeren bir formata dönüştürür. Bu dönüşümde genellikle $Y = 0.299 R + 0.587 G + 0.114 B$ formülü kullanılarak RGB kanallarından tek bir gri seviyeli kanal oluşturulur. Böylece, renk varyasyonlarından kaynaklanan gürültü azalır ve model yalnızca yapısal yüz bilgilerine odaklanabilir; aynı

zamanda aydınlatma koşullarına karşı daha dayanıklı hale gelinir ve hesaplama yükü düşer.

Şekil 3.9’da, Griseviye uygulanmadan önceki orijinal renkli görüntü ile işlem sonrası elde edilen örnek yüz görüntüsü karşılaştırmalı olarak sunulmuştur. Görüldüğü gibi, dönüşüm sonucunda renkli görüntü gri tonlamaya dönüştürülerek aydınlatma farklılıklarının yüz tanıma üzerindeki etkisi minimize edilmiştir.



Şekil 3.9 Griseviye yöntemi uygulandıktan sonra elde edilen örnek yüz görüntüsü

3.3.4. Derin Öğrenme Modeli

Bu çalışmada HOG, LBP ve Griseviye yöntemleriyle elde edilen öznitelik görüntüleri, derin öğrenme modelinin giriş verisi olarak kullanılır. Bu yöntemlerle önceden işlenmiş öznitelikler, modelin daha anlamlı ve seçici bir öğrenme süreci geçirmesini sağlar. Özellikle sınırlı veri durumlarında bu tür klasik öznitelik çıkarımı, derin öğrenme modellerinin daha hızlı ve daha doğru sonuç vermesine katkı sağlar.

Model, eğitim sürecinde bu özniteliklerin arasından en ayırt edici olanları öğrenir ve sınıflandırma işlemini gerçekleştirir. Böylece, modelin genel doğruluk oranı artmakta, özellikle değişken ışık, ifade ve poz durumlarına karşı daha dayanıklı bir sistem elde edilmektedir.

3.3.4.1. Konvolüsyonel Sinir Ağı (CNN) Tabanlı Özellik Çıkarımı Mimarisi


Bu çalışmada kullanılan derin öğrenme modeli, evrimsel sinir ağı (Convolutional Neural Network - CNN) tabanlı çok katmanlı bir mimari olarak tasarlanmıştır. Model, giriş olarak verilen yüz görüntüsünden yüksek düzeyli soyut özellikler çıkartarak, bu özelliklerin sınıflandırıcı katmanlara iletilmesini sağlar. Aşağıda bu mimarinin katman yapısı detaylı olarak açıklanmıştır:

İlk katmanda, 16 adet 3×3 boyutunda filtre içeren evrişim katmanı kullanılmıştır. Bu katman, görüntüdeki düşük seviyeli kenar gibi temel özellikleri çıkarmaktadır. Katmanın çıktısı, Batch Normalization işlemi ile normalize edilmiş, ardından LeakyReLU aktivasyon fonksiyonu ile doğrusal olmayanlık kazandırılmıştır. Bu aktivasyon fonksiyonu, klasik ReLU'nun negatif değerleri tamamen sıfırlamasından farklı olarak, negatif giriş değerlerine küçük bir katsayı ($\alpha = 0.1$) uygular. Sonrasında, 2×2 boyutlu MaxPooling katmanı ile uzamsal boyutlar yarıya indirilerek hesaplama yükü azaltılmış ve Dropout (0.25) ile aşırı öğrenmenin önüne geçilmiştir.

İkinci, üçüncü ve dördüncü katman bloklarında sırasıyla 32, 64 ve 128 filtreli benzer yapıdaki evrişim katmanları kullanılmıştır. Bu katmanlarda Batch Normalization işlemi kullanılmamış, ancak her bir blokta yine LeakyReLU aktivasyonu, MaxPooling ve Dropout işlemleri uygulanmıştır. Bu yapı, ağın her katmanda giderek daha karmaşık yapısal ve anlamsal bilgileri öğrenmesine olanak tanımaktadır.


Beşinci ve son evrişim bloğunda ise 256 filtreli bir Conv2D katmanı kullanılmış, bu katmanın ardından LeakyReLU aktivasyonu, MaxPooling ve bu defa Dropout (0.5) oranıyla daha güçlü bir düzenleme uygulanmıştır. Modelin derinliği ve artan filtre sayısı sayesinde, görüntüdeki yüz hatları, mimik detayları ve diğer ayırt edici özellikler daha etkili şekilde öğrenilebilmektedir.

Model, son evrişim katmanından sonra gelen tam bağlantılı (fully connected) katmanlar ile tamamlanarak, sınıflandırma işlemi gerçekleştirilir. Şekil 3.10'da geliştirilen CNN modelinin mimari yapısı gösterilmiştir.



Şekil 3.10 Geliştirilen CNN modelinin mimari şeması

Keras kullanılarak geliştirilen derin öğrenme modeli, gri tonlamalı (Griseviye), HOG ve LBP öznitelikleri için üç ayrı giriş dalına sahiptir. Her bir giriş dalı, `create_convolution_layers` fonksiyonu ile oluşturulan evrimsel katmanlar içerir. Bu dallar daha sonra birleştirilerek (concatenation), düzleştirme (flattening) işlemi uygulanır ve tam bağlı (dense) katmanlara aktarılır, ardından LeakyReLU aktivasyon fonksiyonu ve Dropout işlemleri uygulanır. Çıkış katmanı olarak, çok sınıflı sınıflandırma için (softmax) aktivasyon fonksiyonunu kullanır. Şekil 3.11’de geliştirilen derin öğrenme modelinin akış şeması gösterilmiştir.



Şekil 3.11 Derin öğrenme modelinin akış şeması

Akış şemasında da görüldüğü üzere, Griseviye, HOG ve LBP öznitelikleri kullanılarak elde edilen görüntülere öncelikle ayrı ayrı CNN modelleri uygulanmış, ardından elde edilen tüm özellikler birleştirilerek sınıflandırma işlemleri gerçekleştirilmiştir.

3.3.5. Veri Artırımı

Derin öğrenme modellerinin genel başarılarını artırmak ve aşırı öğrenme (overfitting) problemini azaltmak amacıyla bu çalışmada çeşitli veri artırma (data augmentation) tekniklerinden faydalanılmıştır. Görüntü verilerine uygulanan bu teknikler, modelin daha genelleyici hale gelmesine katkı sağlarken, eğitim verisinin çeşitlenmesini ve artırılmasını da mümkün kılar.

Bu kapsamda kullanılan veri artırma yöntemleri aşağıda açıklanmıştır:

3.3.5.1. Yatay Yansıtma

Yatay Yansıtma (Horizontal Flip): Görüntülerin yatay ekseninde çevrilmesiyle simetrik varyasyonlar elde edilmiştir. Bu işlem, özellikle yüz gibi simetrik yapılarda modelin öğrenme başarısını artırabilir.

3.3.5.2. Görüntü Kaydırma

Görüntü Kaydırma (Shift): Görüntüler yatay ve dikey eksenlerde belirli piksel miktarlarında kaydırılmıştır. Bu, objelerin pozisyon varyasyonlarına karşı modelin daha dayanıklı hale gelmesini sağlar

3.3.5.3. Görüntü Döndürme

Görüntü Döndürme (Rotate): Görüntüler belirli açılarla döndürülerek yönsel varyasyonlar modele tanıtılmıştır.

3.3.5.4. Görüntülerin Ölçeklendirilmesi

Veri artırma işlemlerine ek olarak, kullanılan görüntülerin boyutları %50 oranında küçültülmüştür. Bu işlem hem hesaplama yükünü azaltmakta hem de modelin daha hızlı eğitilmesini sağlamakta.

Bu veri artırma ve ön işleme adımları, derin öğrenme modelinin farklı varyasyonlardaki görüntüler üzerinde daha başarılı sonuçlar vermesi için iyi bir rol oynamakta.

3.3.6. Kullanılan Derin Öğrenme Metrikleri

Derin öğrenme modellerinin performansını değerlendirmek, modelin gerçek dünya uygulamalarındaki etkinliğini ve doğruluğunu belirlemek için oldukça önemlidir. Bu değerlendirme sürecinde, çeşitli metrikler kullanılarak modelin doğruluğu, hata oranı, öğrenme hızı ve diğer performans göstergeleri ölçülür. Bu metrikler, modelin ne kadar iyi çalıştığını, hangi alanlarda iyileştirme gerektiğini anlamaya yardımcı olur. Derin öğrenme alanında yaygın olarak kullanılan bazı temel performans metrikleri aşağıda açıklanmıştır:

3.3.6.1. Doğruluk (Accuracy)

Sınıflandırma problemlerinde en yaygın kullanılan ve anlaşılması en kolay metriklerden biri olan doğruluk, doğru tahmin edilen örneklerin toplam örnek sayısına oranı olarak hesaplanır. Ancak, doğruluk metriği, veri setindeki sınıfların dengesiz olduğu durumlarda yanıltıcı olabilir. Örneğin, sınıflardan birinin çok daha fazla örneğe sahip olduğu durumlarda, model yalnızca baskın sınıfı tahmin ederek yüksek doğruluk oranları elde edebilir, fakat bu modelin genel başarısını yansıtmaz.

3.3.6.2. Karmaşıklık Matrisi (Confusion Matrix)

Karmaşıklık matrisi, sınıflandırma problemlerinde, modelin tahminlerini gerçek sınıflarla karşılaştırmak için kullanılan önemli bir araçtır. Bu matris, dört ana değeri içerir: doğru pozitif (True Positive, TP), yanlış pozitif (False Positive, FP), doğru negatif (True Negative, TN) ve yanlış negatif (False Negative, FN). Bu dört değer, modelin performansını anlamak için temel bir yapı taşı oluşturur. Karmaşıklık matrisi sayesinde, modelin hangi sınıflarda daha iyi performans gösterdiği, hangi sınıflarda ise hata yaptığı kolayca tespit edilebilir.

3.3.6.3. Hassasiyet (Precision)

Hassasiyet (Precision), modelin pozitif sınıfa ait olduğunu tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösteren bir performans ölçütüdür. Özellikle yanlış pozitiflerin (false positives) önemli olduğu durumlarda tercih edilen bu metrik, Denklem 3.1’de gösterildiği üzere, doğru pozitif (TP) sayısının, doğru pozitifler ile yanlış pozitiflerin (FP) toplamına oranı ile hesaplanır. Yüksek bir hassasiyet değeri, modelin yaptığı pozitif sınıflandırmalarda isabetli olduğunu ve yanlış alarmların düşük olduğunu gösterir.

$$Hassasiyet = \frac{TP}{TP + FP} \quad (3.1)$$

3.3.6.4. Duyarlık (Recall)

Duyarlık (Recall), gerçek pozitif sınıfa ait olan tüm örneklerden kaç tanesinin model tarafından doğru şekilde tespit edildiğini gösteren bir performans ölçütüdür. Özellikle yanlış negatiflerin (false negatives) kritik olduğu uygulamalarda önemli bir rol oynar. Duyarlık, Denklem 3.2’de gösterildiği gibi, doğru pozitif (TP) sayısının, doğru pozitifler ile yanlış negatiflerin (FN) toplamına oranı ile hesaplanır. Yüksek bir duyarlık değeri, modelin hedef sınıfı yüksek oranda başarıyla yakalayabildiğini ifade eder.

$$Duyarlık = \frac{TP}{TP + FN} \quad (3.2)$$

3.3.6.5. F1 Skoru (F1 Score)

F1 skoru, hassasiyet ve duyarlık metriklerinin harmonik ortalamasıdır ve her iki metriği dengeli bir şekilde değerlendiren bir performans ölçüsüdür. Özellikle, bir modelin hassasiyet ve duyarlık arasında bir denge kurması gerektiğinde kullanılır. F1 skoru, her iki metriği de dikkate alarak genel bir performans değerlendirmesi sunar. Bu metrik, özellikle sınıflandırma problemlerinde, her iki hatanın (yanlış pozitif ve yanlış negatif) etkisinin önemli olduğu durumlar için idealdir. F1 skoru aşağıdaki Denklem 3.3’te hesaplanır:

$$F1\ Skoru = 2 * \frac{Hassasiyet \times Duyarluluk}{Hassasiyet + Duyarluluk} \quad (3.3)$$

Bu metriklerin her biri, modelin performansını daha kapsamlı bir şekilde analiz etmek için kullanılır. Her biri farklı bir açıdan modelin güçlü ve zayıf yönlerini ortaya koyarak, modelin geliştirilmesi gereken alanları belirlemeye yardımcı olur. Dolayısıyla, bu metriklerin bir arada kullanılması, modelin gerçek dünya uygulamalarında daha etkili ve güvenilir sonuçlar üretmesini sağlayabilir.



4. BULGULAR

4.1. Çalışmanın Genel Bakışı

Öznitelik çıkarımı sürecinde, her bir veri setine sırasıyla Griseviye, HOG ve LBP yöntemleri uygulanarak öznitelikler elde edilmiş ve bu öznitelikler tek bir bileşik vektör hâline getirilmiştir. Daha sonra, her veri seti için veri bölme oranları veri setinin büyüklüğü ve içeriğine göre özel olarak belirlenmiş ve eğitim, doğrulama ve test kümelerine ayrılmıştır. ORL, PUT ve Yale veri setlerinde genellikle %50 oranında test verisi kullanılırken; Georgia ve FERET veri setlerinde bu oran %20 civarında tutulmuştur. Eğitim ve doğrulama setleri ise %30–%66.67 eğitim ve %10–%33.35 doğrulama aralıklarında olacak şekilde dengelenmiştir.


4.2. ORL Veri Seti Sonuçları

Bu çalışma kapsamında, ORL yüz tanıma veri seti üzerinde yapılan farklı veri bölme oranlarıyla gerçekleştirilen model eğitimi ve değerlendirme süreci analiz edilmiştir. Veri seti 40 sınıftan oluşmakta olup, her sınıf 10 görüntüden toplam 400 görüntü içermektedir. Bu çalışmada veri seti %35 eğitim, %15 doğrulama ve %50 test oranlarında ayrılmıştır. Bu dağılım, modelin daha sınırlı eğitim verisiyle öğrenmesini sağlarken, doğrulama ve test verileri üzerinde genelleme kabiliyetini değerlendirmek açısından anlamlıdır.


4.2.1. Eğitim ve Doğrulama Sonuçları

Modelin 34. epoch sonunda elde ettiği eğitim ve doğrulama sonuçları aşağıda verilmiştir. Doğruluk grafiği Şekil 4.1'de, kayıp grafiği ise Şekil 4.2'de gösterilmektedir.

- Eğitim doğruluğu (accuracy): %99.73
- Eğitim kaybı (loss): 0.0172
- Doğrulama doğruluğu (val_accuracy): %98.33
- Doğrulama kaybı (val_loss): 0.0368



Şekil 4.1 ORL veri seti doğruluk grafiği



Şekil 4.2 ORL veri seti hata grafiği

4.2.2. Test Sonuçları


- Test doğruluğu (test accuracy): %99.00
- Test kaybı (test loss): 0.0365

Test sonuçlarının her iki değerlendirme çıktısında da tutarlı olması, modelin farklı test koşullarında kararlı performans sergilediğini göstermektedir.

4.2.3. Ek Değerlendirme Metrikleri

- Kesinlik (Precision) ortalaması: 0.9917(99.17%~)
- Duyarlılık (Recall) ortalaması: 0.9900(99.00%~)
- F1-score ortalaması: 0.9899 (~%98.99)

Karmaşıklık matrisinden seçilmiş birkaç sınıfa ait örnekler Şekil 4.3'te sunulmuştur. Örneğin 38. sınıf için 5 pozitif örneğin tümü doğru pozitif (true positive) olarak sınıflandırılmış; geri kalan 195 örnekten 194'ü doğru negatif (true negative), yalnızca 1'i yanlış pozitif (false positive) olarak etiketlenmiştir.




Şekil 4.3 ORL veri seti karmaşıklık matrisinden örnek görüntüler

4.2.4. Yorum ve Değerlendirme

ORL veri seti deneysel sonuçları, sınırlı eğitim verisiyle dahi modelin olağanüstü performans gösterebildiğini ortaya koymuştur. Eğitim ve doğrulama doğruluklarının %98'in üzerinde olması, öğrenmenin etkili biçimde gerçekleştiğini göstermektedir. Test doğruluklarının %99 seviyesine ulaşması ise modelin yalnızca eğitim verisini değil, daha önce karşılaşmadığı örnekleri de doğru sınıflandırma yeteneğine sahip olduğunu göstermektedir. Özellikle precision, recall ve F1-score değerlerinin birbirine çok yakın ve %99 düzeyinde olması, sınıflar arasında hem hata oranlarının düşük olduğunu hem de modelin kararlılığını kanıtlamaktadır.

ORL veri seti üzerinde farklı yüz tanıma yöntemlerinin doğruluk oranları Şekil 4.4'te görselleştirilmiştir. Şekilden de anlaşılacağı üzere, hibert modelimiz %99.73 doğruluk oranı ile tüm klasik yöntemleri geride bırakmıştır. Özellikle HOG-LDB + SVDL (%96.1) ve ICA (%88.0) (Bartlett vd. 2002, Wang vd., 2019), gibi gelişmiş yöntemlerle karşılaştırıldığında, modelin belirgin bir üstünlük sergilediği görülmektedir. Bu durum, modelin yalnızca yüksek ayırt edicilik kabiliyetine değil, aynı zamanda güçlü bir genelleme yeteneğine de sahip olduğunu açıkça ortaya koymaktadır.



Şekil 4.4 ORL veri seti üzerinde uygulanan farklı yüz tanıma yöntemlerinin doğruluk oranlarının karşılaştırılması


4.3. PUT Veri Seti Sonuçları

Bu çalışma kullanılan diğer veri seti, PUT yüz tanıma veri seti 100 farklı sınıf ve her sınıf için 10 görüntüden oluşmakta olup, toplam 1000 görüntü içermektedir. Veri seti %50 test, %40 eğitim ve %10 doğrulama oranlarında üç alt kümeye ayrılmıştır. Bu yapı, modelin öğrenme ve genelleme yeteneklerinin etkin biçimde test edilmesine olanak sağlamaktadır.


4.3.1. Eğitim ve Doğrulama Sonuçları

Modelin 33. epoch sonunda elde ettiği eğitim ve doğrulama sonuçları aşağıda verilmiştir. Doğruluk grafiği Şekil 4.5'te, kayıp grafiği ise Şekil 4.6'de gösterilmektedir.

- Eğitim doğruluğu (accuracy): %99.06
- Eğitim kaybı (loss): 0.0431
- Doğrulama doğruluğu (val_accuracy): %100.00
- Doğrulama kaybı (val_loss): 0.0073



Şekil 4.5 PUT veri seti doğruluk grafiği



Şekil 4.6 PUT veri seti kayıp grafiği

4.3.2. Test Sonuçları

- Test doğruluğu (test accuracy): %97.80
- Test kaybı (test loss): 0.0736

Test sonuçlarının her iki değerlendirme çıktısında da tutarlı olması, modelin farklı test koşullarında kararlı performans sergilediğini göstermektedir.


4.3.3. Ek Değerlendirme Metrikleri

- Kesinlik (Precision) ortalaması: 0.9826 (~%98.26)
- Duyarlılık (Recall) ortalaması: 0.9780 (~%97.80)
- F1-score ortalaması: 0.9778 (~%97.78)

PUT veri seti üzerinde elde edilen %98.26 kesinlik, %97.80 duyarlılık ve %97.78 F1-score değerleri, modelin sınıflar arasında yüksek doğrulukla ve dengeli şekilde çalıştığını göstermektedir. Bu metrikler, modelin hem yanlış pozitif hem de yanlış negatif tahminleri minimum düzeyde tuttuğunu, böylece güvenilir ve uygulamaya uygun bir sınıflandırma

başarımı sergilediğini ortaya koymaktadır. Bu sonuçlar, modelin genel kararlılığını ve yüz tanıma görevlerindeki etkinliğini desteklemektedir.

Karmaşıklık matrisinden seçilmiş birkaç sınıfa ait örnekler Şekil 4.7'de sunulmuştur. Örneğin, 48. sınıf için dört pozitif örneğin tamamı doğru pozitif (true positive) olarak sınıflandırılmış; geri kalan 496 örnekten 495'i doğru negatif (true negative) ve yalnızca biri yanlış pozitif (false positive) olarak etiketlenmiştir. Bu durum, modelin genel olarak bu sınıfı yüksek isabetle tanıdığını ancak sınıflar arası küçük çaplı karışıklık yaşadığını göstermektedir. Benzer şekilde, 18. sınıf için beş pozitif örneğin tamamı doğru pozitif olarak sınıflandırılmış ve geri kalan 495 örneğin tümü doğru negatif olarak etiketlenmiştir. Bu sonuç, modelin bu sınıfı tamamen hatasız bir şekilde ayırt edebildiğini ve sınıflar arası ayırım performansının oldukça yüksek olduğunu göstermektedir.



Şekil 4.7 PUT veri seti karmaşıklık matrisinden örnek görüntüler

4.3.4. Yorum ve Değerlendirme

Bu deneysel sonuçlar, modelin yalnızca eğitim verisi üzerinde değil, daha önce hiç görmediği doğrulama ve test verileri üzerinde de üstün bir başarı sergilediğini ortaya koymaktadır. Doğrulama doğruluğunun %100 olması, modelin öğrenme sürecinde aşırı öğrenme (overfitting) yapmaksızın yüksek bir genelleme kapasitesine ulaştığını

göstermektedir. Doğrulama ve test kaybı değerlerinin düşük olması ise tahminlerin oldukça küçük hata paylarıyla gerçekleştirildiğini ifade etmektedir. Precision, recall ve F1-score değerlerinin %97–98 aralığında olması, sınıflar arası ayırım gücünün yüksek olduğunu ve sınıflandırma başarımının dengeli bir şekilde sağlandığını göstermektedir.

4.4. Yale Veri Seti Sonuçları

Bu bölümde, Yale yüz tanıma veri seti üzerinde gerçekleştirilen deneysel çalışmanın sonuçları değerlendirilmiştir. Veri seti, her biri 60 ila 65 arasında değişen sayıda görüntü içeren 39 farklı sınıftan oluşmakta olup, toplamda yaklaşık 2452 görüntü içermektedir. Bu çalışma kapsamında kullanılan en büyük veri seti olma özelliğine sahiptir. Görseller, %50 test, %40 eğitim ve %10 doğrulama oranlarında üç alt kümeye ayrılarak modellenmiştir. Bu yapı, sınıflar arası ayırım gücünü değerlendirebilmek için dengeli bir örnekleme imkânı sunmaktadır.

4.4.1. Eğitim ve Doğrulama Sonuçları

Modelin 28. epoch sonunda elde ettiği eğitim ve doğrulama sonuçları aşağıda verilmiştir. Doğruluk grafiği Şekil 4.8'de, kayıp grafiği ise Şekil 4.9'de gösterilmektedir.


- Eğitim doğruluğu (accuracy): %99.50
- Eğitim kaybı (loss): 0.0197
- Doğrulama doğruluğu (val_accuracy): %96.75
- Doğrulama kaybı (val_loss): 0.2147

4.4.2. Test Sonuçları


- Test doğruluğu (test accuracy): %95.76
- Test kaybı (test loss): 0.2560

Model, tüm eğitim sürecinden sonra test verilerinde de yüksek doğruluk sağlamıştır. Bu, modelin genelleme gücünün kuvvetli olduğunu gösterir. Kaybın doğruluğa oranla biraz

yüksek olması, bazı sınıflarda düşük olasılıkla yapılan tahminler olduğunu ve belki de dengesiz sınıflarla karşılaşıldığını düşündürmektedir.



Şekil 4.8 Yale veri seti doğruluk grafiği



Şekil 4.9 Yale veri seti kayıp grafiği

4.4.3. Ek Değerlendirme Metrikleri

- Kesinlik (Precision) ortalaması: 0.9610 (~%96.10)
- Duyarlılık (Recall) ortalaması: 0.9574 (~%95.74)
- F1-score ortalaması: 0.9577 (~%95.77)

Precision, recall ve F1-score değerlerinin tamamının %95'in üzerinde olması, sınıflar arası ayırımın yüksek doğrulukla yapılabildiğini ve modelin istikrarlı bir karar mekanizması sunduğunu göstermektedir. Test kaybının nispeten yüksek olması, modelin bazı sınıflarda daha düşük güvenle tahminlerde bulunduğunu, bu durumun sınıf içi benzerlikler veya veri dengesizliğinden kaynaklanabileceğini düşündürmektedir.


Karmaşıklık matrisinden seçilmiş bazı sınıflara ait örnekler Şekil 4.10'de sunulmuştur. Görüldüğü üzere, modelin sınıf bazında doğruluk oranı oldukça yüksektir. Özellikle 4, 14, 19 ve 32 numaralı sınıflarda neredeyse hatasız tahminler gerçekleştirilmiştir. En fazla hata yapılan sınıf ise 13. sınıf olarak öne çıkmaktadır (6 yanlış negatif, 2 yanlış pozitif). Benzer şekilde, 27. sınıfta da görece daha yüksek sayıda yanlış pozitif tahmin gözlemlenmiştir (5 örnek); bu durum, modelin bazı örnekleri hatalı şekilde bu sınıfa atadığını göstermektedir. Genel olarak değerlendirildiğinde, karmaşıklık matrisleri modelin sınıfların büyük çoğunluğunu doğru biçimde tanımlayabildiğini ortaya koymakta; yalnızca sınırlı sayıda sınıfta görece yüksek hata oranlarıyla karşılaşılmaktadır. Bu bulgular, modelin güçlü bir genelleme kapasitesine sahip olduğunu, ancak bazı sınıflarda daha derinlemesine öz nitelik ayrıştırmasına veya veri çeşitliliğine ihtiyaç duyulabileceğini göstermektedir.

4.4.4. Yorum ve Değerlendirme


Modelin Yale veri seti üzerinde gerçekleştirdiği eğitim, doğrulama ve test süreçleri sonucunda elde edilen doğruluk ve kayıp değerleri, derin öğrenme yöntemlerinin bu tür yüz tanıma görevlerinde yüksek başarı sağlayabildiğini ortaya koymaktadır. Özellikle eğitim doğruluğunun %99.50 gibi üst düzey bir seviyede olması, modelin veri içi örüntüleri etkili bir biçimde öğrendiğini göstermektedir. Doğrulama ve test

doğruluklarının sırasıyla %96.75 ve %95.76 düzeylerinde gerçekleşmesi ise modelin güçlü bir genelleme kapasitesine sahip olduğunu ortaya koymaktadır.

Şekil 4.11’de, literatürde yer alan geleneksel ve gelişmiş yöntemlerle, bu tez kapsamında önerilen HOG, LBP ve Griseviye ön işleme adımlarını içeren derin öğrenme tabanlı yaklaşımın, Extended Yale B veri seti üzerindeki sınıflandırma doğrulukları karşılaştırmalı olarak sunulmuştur. Geleneksel yöntemler — örneğin Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (NN) ve Seyrek Temsile Dayalı Sınıflandırma (SRC) — %50’nin altında doğruluk oranları sergilemiştir (Deng, Hu ve Guo, 2012; Ding vd., 2017). Buna karşılık, DMMA, ESRC ve LGR gibi daha gelişmiş yöntemler %60 ila %86 aralığında sonuçlar elde etmiştir. Literatürde yaygın olarak kullanılan HOG–LDB + SVDL yöntemi, %98,6 doğruluk oranı ile yüksek performans göstermiş olsa da, bu tez kapsamında geliştirilen hibrit model %99,5 doğruluk oranı ile tüm yöntemleri geride bırakmıştır. Bu sonuçlar, klasik öznitelik çıkarım tekniklerinin derin öğrenme mimarileriyle bütünleştirilmesinin, özellikle yüksek varyans içeren veri setlerinde daha güçlü genelleme yeteneği ve üstün sınıflandırma başarısı sağladığını açıkça ortaya koymaktadır.



Şekil 4.10 Yale veri seti karmaşıklık matrisinden örnek görüntüler



Şekil 4.11 Yale veri seti üzerinde literatürdeki yöntemler ile HOG, LBP, Griseviye + derin öğrenme yönteminin karşılaştırması

4.5. Georgia Veri Seti Sonuçları


Bu bölümde, Georgia yüz tanıma veri seti üzerinde gerçekleştirilen derin öğrenme tabanlı model eğitimi ve değerlendirme süreci sunulmaktadır. Veri seti, her biri 15 örnek içeren 50 sınıftan oluşmaktadır ve toplamda 750 görüntüden meydana gelmektedir. Veri seti %66.67 eğitim, %13.33 doğrulama ve %20 test oranlarında ayrılmıştır. Bu ayırım, modelin hem öğrenme hem de genelleme performansını dengeli bir şekilde test edebilmek amacıyla belirlenmiştir.

4.5.1. Eğitim ve Doğrulama Sonuçları


Modelin 33. epoch sonunda elde ettiği eğitim ve doğrulama sonuçları aşağıda verilmiştir. Doğruluk grafiği Şekil 4.12'de, kayıp grafiği ise Şekil 4.13'te gösterilmektedir.

- Eğitim doğruluğu (accuracy): %99.60
- Eğitim kaybı (loss): 0.0123
- Doğrulama doğruluğu (val_accuracy): %97.00
- Doğrulama kaybı (val_loss): 0.1255

Bu sonuçlar, modelin öğrenme sürecinde yüksek başarı sağladığını ve doğrulama verisinde genelleme yeteneğini koruyabildiğini göstermektedir.



Şekil 4.12 Georgia veri seti doğruluk grafiği



Şekil 4.13 Georgia veri seti kayıp grafiği

4.5.2. Test Sonuçları

- Test doğruluğu (test accuracy): %95.33
- Test kaybı (test loss): 0.1696

Test sürecinde elde edilen sonuçlar, modelin eğitimde öğrendiklerini başarılı bir şekilde genellebileceğini ortaya koymaktadır. Test doğruluğunun %95'in üzerinde olması, modelin sağlam ve tutarlı performans gösterdiğini kanıtlamaktadır.

4.5.3. Ek Değerlendirme Metrikleri

- Kesinlik (Precision) ortalaması: 0.965 (96.5%~)
- Duyarlılık (Recall) ortalaması: 0.9533 (95.33%~)
- F1-score ortalaması: 0.9500 (~%95.00)


Bu değerlere göre, model hem hatalı sınıflamadan kaçınmakta hem de doğru sınıflamaları yüksek oranda gerçekleştirmektedir.

Karmaşıklık matrislerinden seçilmiş birkaç sınıfa ait örnekler Şekil 4.14'te incelendiğinde, çoğu sınıf için yanlış pozitif (false positive) ve yanlış negatif (false negative) oranlarının son derece düşük olduğu görülmektedir. Örneğin 6., 21. ve 47. sınıflarda tüm pozitif örnekler doğru şekilde sınıflandırılmış (true positive) ve hiçbir yanlış sınıflama yapılmamıştır. Benzer şekilde, 11. sınıf için yalnızca 1 yanlış pozitif gözlenmiştir; 18. ve 34. sınıflarda ise her biri için yalnızca 1 örnek yanlış negatif olarak etiketlenmiştir. Bu sonuçlar, modelin hem pozitif sınıfları doğru tanıma hem de negatif örnekleri dışlama konusunda oldukça başarılı olduğunu ortaya koymaktadır. Bu da modelin genelleme yeteneğinin yüksek olduğuna işaret etmektedir.

4.5.4. Yorum ve Değerlendirme

Georgia veri seti üzerinde gerçekleştirilen bu deneysel çalışma, derin öğrenme tabanlı yaklaşımın büyük ve çok sınıflı veri setlerinde dahi etkili bir şekilde çalışabildiğini ortaya koymaktadır. Elde edilen %99.60 eğitim doğruluğu ile %97 doğrulama doğruluğu,

modelin hem öğrenme sürecini başarıyla tamamladığını hem de genelleme yeteneğinin güçlü olduğunu göstermektedir. Test aşamasında elde edilen %95.33 doğruluk oranı ve %0.95 F1-skora, modelin yüksek isabetle tahminlerde bulunduğunu ve sınıflar arası kararlılıkla çalıştığını kanıtlamaktadır. Test kaybının nispeten yüksek olması, bazı sınıflar arasında gözlemlenen benzerliklerin modelin kararlarında sınırlı düzeyde belirsizlik yaratabileceğini düşündürmektedir. Ancak genel değerlendirme itibarıyla, modelin performansı bu tür yüksek kapasiteli veri setlerinde oldukça tatmin edici düzeydedir ve yüz tanıma sistemlerinde güvenle kullanılabilir niteliktedir.



Şekil 4.14 Georgia veri seti karmaşıklık matrisinden örnek görüntüler

4.6. Feret Veri Seti Sonuçları

Bu bölümde, FERET yüz tanıma veri seti üzerinde gerçekleştirilen derin öğrenme modeli eğitimi ve performans analizi sunulmaktadır. FERET veri seti, her biri 10 görüntü içeren 194 sınıftan oluşmakta olup toplamda 1940 görüntüden meydana gelmektedir. Bu çalışma kapsamında veri seti %46.65 eğitim, %33.35 doğrulama ve %20 test oranlarında


ayrılmıştır. Bu oranlar, sınırlı sayıda örnekle modelin hem öğrenme hem de genelleme kabiliyetini etkili biçimde değerlendirmek amacıyla belirlenmiştir.

4.6.1. Eğitim ve Doğrulama Sonuçları


Modelin 31. epoch sonunda elde ettiği eğitim ve doğrulama sonuçları aşağıda verilmiştir. Doğruluk grafiği Şekil 4.15'te, kayıp grafiği ise Şekil 4.16'de gösterilmektedir.

- Eğitim doğruluğu (accuracy): %99,43
- Eğitim kaybı (loss): 0.0175
- Doğrulama doğruluğu (val_accuracy): %97,68
- Doğrulama kaybı (val_loss): 0.0932

Bu sonuçlar, modelin öğrenme sürecinde oldukça başarılı olduğunu ve doğrulama verisi üzerinde yüksek bir genelleme kapasitesine sahip olduğunu göstermektedir.



Şekil 4.15 Feret veri seti doğruluk grafiği



Şekil 4.16 Feret veri seti hata grafiği

4.6.2. Test Sonuçları

- Test doğruluğu (test accuracy): %97.37
- Test kaybı (test loss): 0.0969

Test sonuçları, modelin daha önce görmediği veriler üzerinde yüksek performans sergileyebildiğini ve eğitim sürecinde elde edilen başarıyı etkili bir şekilde genelleyebildiğini göstermektedir.


4.6.3. Ek Değerlendirme Metrikleri

- Kesinlik (Precision) ortalaması: 0.9789 (~%97.89)
- Duyarlılık (Recall) ortalaması: 0.9721 (~%97.21)
- F1-score ortalaması: 0.9706 (~%97.06)

Bu metrikler, modelin hem doğru pozitif sınıflandırmalarda hem de tüm pozitif örnekleri kapsama konusunda oldukça yüksek performans gösterdiğini ortaya koymaktadır. F1-

score'un yüksek olması, modelin hem kesinlik hem de duyarlılık açısından dengeli çalıştığını göstermektedir.

Karmaşıklık matrislerinden seçilen bazı sınıflara ait örnekler Şekil 4.17'de incelendiğinde, yanlış pozitif (false positive) ve yanlış negatif (false negative) oranlarının büyük ölçüde ihmal edilebilir düzeyde olduğu görülmektedir. Örneğin, 2, 6, 47, 119, 144 ve 185 numaralı sınıflarda tüm pozitif örnekler doğru şekilde sınıflandırılmış (true positive) ve hiç yanlış sınıflama yapılmamıştır. 20 numaralı sınıf için yalnızca bir yanlış pozitif, 31 numaralı sınıf için ise yalnızca bir yanlış negatif gözlenmiştir. Bu bulgular, modelin hem pozitif örnekleri doğru tanıma hem de negatif örnekleri dışlama konusunda son derece başarılı olduğunu; dolayısıyla genelleme yeteneğinin yüksek olduğunu kanıtlamaktadır.



Şekil 4.17 Feret veri seti karmaşıklık matrisinden örnek görüntüler

4.6.4. Yorum ve Değerlendirme


FERET veri seti üzerinde gerçekleştirilen bu deney, sınıf başına az sayıda örnek içeren veri setlerinde bile derin öğrenme temelli modellerin yüksek doğrulukla çalışabildiğini göstermektedir. Modelimizde elde edilen eğitim doğruluğu %99,43, doğrulama doğruluğu %97,68 ve test doğruluğu %97,37 olarak gerçekleşmiştir. Benzer sonuçların farklı test döngülerinde de tutarlı bir şekilde tekrarlanması, modelin genelleme

kabiliyetini güçlendirmektedir. Precision, recall ve F1-score metriklerinin tümünün %97 bandında seyretmesi, sınıflandırma performansının hem dengeli hem de güvenilir olduğunu ortaya koymaktadır.

Şekil 4.18’de FERET veri seti üzerinde literatürdeki yöntemlerle “HOG, LBP, Griseviye + Derin Öğrenme” yönteminin karşılaştırılması sunulmuştur. Buna göre:

1. EBGM ortalaması: %80,3 (Verma ve Khunteta, 2018)
2. ICA yöntemleri ortalaması: %87,1 (Bartlett vd. 2002)
3. HOG–EBGM ortalaması: %73,3 (Albiol vd., 2008)
4. HOG–DMMA: %97,0 (Ji vd., 2016)
5. Wavelet LBP: %96,3 (Tuncer vd, 2019)
6. HOG, LBP, Griseviye + Derin Öğrenme: %99,43

Bu bulgular, önerdiğimiz hibrit derin öğrenme yaklaşımının FERET’teki poz, ifade ve zaman varyasyonlarına karşı literatürdeki en iyi öznetelik-tabanlı yöntemleri bile anlamlı bir farkla geride bıraktığını kanıtlamaktadır.



Şekil 4.18 FERET veri seti üzerinde literatürdeki yöntemler ile HOG, LBP, Griseviye + derin öğrenme yönteminin karşılaştırması

5. TARTIŞMA ve SONUÇ

Bu çalışmada, yüz tanıma alanında kullanılan geleneksel öznitelik çıkarım tekniklerinin (Griseviye, HOG ve LBP) birleştirilmesiyle oluşturulan ve derin öğrenme mimarileriyle bütünleştirilen hibrit bir yaklaşım sunulmuştur. Geliştirilen sistem, ORL, PUT, Yale, Georgia ve FERET olmak üzere beş farklı yüz tanıma veri seti üzerinde değerlendirilmiş; her bir veri seti için eğitim, doğrulama ve test aşamalarına ilişkin ayrıntılı performans analizleri gerçekleştirilmiştir.

Model eğitimi öncesinde her veri seti için veri bölme oranları, veri setinin büyüklüğü ve içeriğine göre özel olarak belirlenmiş ve eğitim, doğrulama ve test kümelerine ayrılmıştır. Çizelge 5.1’de görüldüğü üzere, ORL, PUT ve Yale veri setlerinde genellikle %50 oranında test verisi kullanılırken; Georgia ve FERET veri setlerinde bu oran %20 civarında tutulmuştur. Eğitim ve doğrulama setleri ise %30–%66.67 eğitim ve %10–%33.35 doğrulama aralıklarında olacak şekilde dengelenmiştir.


Çizelge 5.1 Veri setlerine ait sınıf, görüntü sayısı ve bölme oranları

Veri Seti	Sınıf Sayısı	Toplam Görüntü	Eğitim (%)	Doğrulama (%)	Test (%)
ORL	40	400	35	15	50
PUT	100	1000	40	10	50
Yale	39	2452	40	10	50
Georgia	50	750	66.67	13.33	20
FERET	194	1940	46.65	33.35	20

Bu farklı bölme oranları, her veri setinin kendine özgü yapısı göz önünde bulundurularak belirlenmiş; sınıf sayısı, toplam görüntü sayısı, aydınlatma koşulları, poz varyasyonları ve arka plan çeşitliliği gibi faktörler dikkate alınmıştır. Özellikle test setinin %50 olduğu durumlar, modelin her sınıf için yeterli sayıda "görmediği" örnek üzerinden değerlendirildiği ve böylelikle modelin genelleme yeteneğinin daha gerçekçi biçimde ölçülebildiği durumları yansıtmaktadır. Buna karşılık, daha büyük veri setlerinde test

oranının daha düşük tutulması, eğitim verisinin artırılarak modelin öğrenme kapasitesinin maksimize edilmesini sağlamıştır.

Şekil 5.1’de yer alan veri seti karşılaştırma grafiği, hem sınıf sayıları hem de toplam görüntü sayılarının görsel olarak karşılaştırılmasını sağlayarak, veri çeşitliliği ve modelin ölçeklenebilirlik ihtiyaçlarını daha net ortaya koymaktadır.




Şekil 5.1 Veri setlerine göre sınıf ve görüntü sayıları

Eğitim oranının %30–%66.67 arasında değişmesi, bazı veri setlerinde overfitting riskini artırabilse de, doğrulama setinin %10–%33.35 arasında tutulması ile bu risk hiperparametre ayarlamaları yoluyla dengelenmiş ve modelin kararlı bir şekilde optimize edilmesi sağlanmıştır. Her veri seti için uygulanan bu özelleştirilmiş bölme stratejisi, modelin hem öğrenme süreci hem de test performansının adil ve temsil edici bir şekilde değerlendirilebilmesine olanak tanımıştır.

Elde edilen bulgular, sınıf sayısı, örnek sayısı ve çeşitlilik bakımından birbirinden oldukça farklı yapıya sahip veri setlerinde dahi modelin yüksek sınıflandırma başarımı ortaya koyduğunu göstermektedir. Şekil 5.2’de sunulan doğruluk grafiğine göre eğitim doğruluğu çoğu veri setinde %99’un üzerine çıkarken; doğrulama doğruluğu da %96 ila


%100 aralığında seyretmiştir. Bu durum, modelin yalnızca öğrenme sürecinde değil, daha önce karşılaşmadığı örneklerde de yüksek doğrulukla tahmin yapabildiğini ve güçlü bir genelleme kapasitesine sahip olduğunu ortaya koymaktadır.



Şekil 5.2 Veri setlerine göre eğitim ve doğrulama doğruluk oranları

Ayrıca Şekil 5.3'te gösterilen eğitim ve doğrulama hata oranlarına bakıldığında, tüm veri setlerinde hata oranlarının oldukça düşük seviyelerde kaldığı görülmektedir. En düşük hata oranı PUT veri setinde (%0 doğrulama hatası), en yüksek ise Yale veri setinde (%3.25 doğrulama hatası) gözlemlenmiştir. Bu durum, modelin sınıf çeşitliliği yüksek veri setlerinde bile etkili şekilde genellebildiğini göstermektedir.

Ek değerlendirme metrikleri olan kesinlik (precision), duyarlılık (recall) ve F1-skor değerleri, tüm veri setlerinde %95'in üzerinde gerçekleşmiştir. Bu bulgular, modelin yalnızca yüksek doğrulukla çalışmakla kalmadığını, aynı zamanda sınıflar arasında dengeli ve kararlı bir sınıflandırma performansı sunduğunu göstermektedir. PUT, Yale, Georgia ve FERET gibi yüksek sınıf sayısı, örnek çeşitliliği ve veri hacmine sahip, çok sınıflı veri yapılarında elde edilen yüksek başarı oranları; modelin ölçeklenebilirliğini ve gerçek dünya koşullarına uyum sağlama potansiyelini güçlü bir biçimde ortaya koymaktadır.



Şekil 5.3 Veri setlerine göre eğitim ve doğrulama hata oranları

Karmaşıklık matrisi analizleri ise çoğu sınıfta hatasız sınıflamalar yapıldığını; sınırlı sayıda sınıfta ise düşük oranlı yanlış pozitif (false positive) ve yanlış negatif (false negative) tahminlerin gerçekleştiğini göstermektedir. Bu tür hataların temel nedeninin sınıf içi benzerlikler, poz ve ifade varyasyonları gibi görsel benzerlikler olduğu değerlendirilmektedir. Bu bağlamda, daha dengeli veri örnekleme, veri artırma (augmentation) ve model mimarisi iyileştirmeleri ile hata oranlarının daha da azaltılması mümkündür.

Sonuç olarak, Griseviye, HOG ve LBP özniteliklerinin birleştirilmesiyle oluşturulan hibrit derin öğrenme modeli:

- Geleneksel yöntemlere kıyasla çok daha yüksek doğruluk sağlamış,
- Düşük örnek sayısıyla dahi etkili öğrenme başarısı göstermiş,
- Veri setine özgü farklılıkları başarılı şekilde tolere edebilmiş,
- Literatürde yer alan birçok gelişmiş yöntemi geride bırakmıştır.

Bu yönleriyle geliştirilen model, özellikle düşük veri hacmine sahip, poz ve ifade çeşitliliği içeren yüz tanıma senaryoları başta olmak üzere çok çeşitli uygulamalarda güvenle kullanılabilir. Gelecek çalışmalarda, modelin video tabanlı yüz tanıma, veri artırma tekniklerinin entegrasyonu ve öznetelik seçimini dinamik hale getiren optimizasyon algoritmaları ile daha da geliştirilmesi hedeflenebilir.



6. KAYNAKLAR

- Abuzneid, M.A., Mahmood, A., 2018, Enhanced human face recognition using LBPH descriptor, multi-KNN, and back-propagation neural network, *IEEE Access*, 6: 20641–20651.
- Ahonen, T., Rahtu, E., Ojansivu, V., Heikkilä, J., 2008, Recognition of blurred faces using local phase quantization, In: 19th Int. Conf. on Pattern Recognition, pp. 1–4.
- Albiol, A., et al., 2008, Face recognition using HOG–EBGM, *Pattern Recognition Letters*, 29(10): 1537–1543.
- Bartlett, M.S., 2007, Information maximization in face processing, *J. Neurocomputing*, 70: 2204–2217.
- Bartlett, M.S., Movellan, J.R., Sejnowski, T.J., 2002, Face recognition by independent component analysis, *IEEE Trans. Neural Networks*, 13(6): 1450–1464.
- Belhumeur, P.N., Hespanha, J.P., Kriegman, D.J., 1997, Eigenfaces against Fisherfaces: recognition using class specific linear projection, *IEEE Trans. Patt. Anal. Mach. Intell.*, 19(7): 711–720.
- Belkin, M., Niyogi, P., 2003, Laplacian eigenmaps for dimensionality reduction and data representation, *Neural Comput.*, 15(6): 1373–1396.
- Bell, A., Sejnowski, T., 1995, An information-maximization approach to blind separation and blind deconvolution, *J. Neural Computation*, 7: 1004–1034.
- Beyer, K., Goldstein, J., Ramakrishnan, R., Shaft, U., 1999, When is “nearest neighbor” meaningful?, In: *Int. Conf. on Database Theory*, Springer, Berlin, Heidelberg, pp. 217–235.
- Bledsoe, W., 1964, The model method in facial recognition, Panoramic Research Inc., Tech. Rep. PRI:15, Palo Alto, CA.
- Borade, S.N., Deshmukh, R., Shrishrimal, P., 2015, Independent Component Analysis and Number of Independent Basis Vectors, *Procedia Computer Science*, 58: 380–386.

- Dalal, N., Triggs, B., 2005, Histograms of Oriented Gradients for Human Detection, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 1: 886–893.
- Daugman, J.G., 1988, Complete Discrete 2D Gabor Transform by Neural Networks for Image Analysis and Compression, IEEE Trans. Acoustics, Speech, and Signal Processing, 36: 1169–1179.
- Deng, W.H., Hu, J.N., Guo, J., 2012, Extended SRC: undersampled face recognition via intraclass variant dictionary, IEEE Trans. Patt. Anal. Mach. Intell., 34(9): 1864–1870.
- Ding, C.H., Bao, T.L., Karmoshi, S., et al., 2017, Single sample per person face recognition with KPCANet and a weighted voting scheme, Signal Image Video Process., 11(7): 1213–1220.
- Donuk, K., et al., 2021, Deep feature selection for facial emotion recognition based on BPSO and SVM, Politeknik Dergisi, 2021: 1–1.
- Georghiades, A. S., Belhumeur, P. N., Kriegman, D. J., 2001, From few to many: illumination cone models for face recognition under variable lighting and pose, IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(6): 643–660.
- Ji, Q., et al., 2016, Face recognition method based on HOG and DMMA from single training sample, Multimedia Tools and Applications, 75: 13163–13177.
- Kasinski, A., Florek, A., Schmidt, A., 2008, The PUT face database, Image Processing and Communications, 13: 59–64.
- Mehta, N., Jadhav, S., 2017, Facial emotion recognition using log gabor filter and PCA, Proc. 2nd Int. Conf. on Computing, Communication, Control and Automation (ICCUBEA), 1–5.
- Ojala, T., Pietikäinen, M., Harwood, D., 1996, Performance evaluation of texture measures with classification based on Kullback discrimination of distributions, Pattern Recognition, 29(1): 51–59.
- Penev, A., Atick, J., 1996, Local feature analysis: a general statistical theory for object representation, Netw. Comput. Neural Syst., 7(3): 477–500.

- Phillips, P. J., Rauss, P., Der, S., 1996, FERET (face recognition technology) recognition algorithm development and test report, Technical Report ARL-TR-995, U.S. Army Research Laboratory.
- Radman, A., Suandi, S.A., 2018, Robust face pseudo-sketch synthesis and recognition using morphological-arithmetic operations and HOG-PCA, *Multimedia Tools and Applications*, 77: 25311–25332.
- Rauss, P., Phillips, P. J., DePersia, A. T., Hamilton, M., 1996, Face recognition technology program overview and results, 25th AIPR Workshop: Emerging Applications of Computer Vision, SPIE 2962: 253–263.
- Samaria, F., Harter, A., 1994, Parameterisation of a Stochastic Model for Human Face Identification, *Proceedings of the 2nd IEEE Workshop on Applications of Computer Vision*, Sarasota, Florida, USA: 138–142.
- Struc, V., Pavešić, N., 2010, The complete Gabor-Fisher classifier for robust face recognition, *EURASIP J. Adv. Signal Process.*, 2010: 1–26.
- Struc, V.V.V., Pavešić, N., 2009, Gabor-based kernel partial-least-squares discrimination features for face recognition, *Informatica*, 20(1): 115–138.
- Tenenbaum, J.B., De Silva, V., Langford, J.C., 2000, A global geometric framework for nonlinear dimensionality reduction, *Science*, 290(5500): 2319–2323.
- Tuncer, T., et al., 2019, Face recognition with triangular fuzzy set-based local cross patterns in wavelet domain, *Symmetry*, 11(6): 787.
- Turk, M., Pentland, A., 1991, Eigenfaces for recognition, *J. Cognit. Neurosci.*, 3(1): 71–86.
- Verma, K., Khunteta, A., 2018, Facial expression recognition using Gabor filter and multi-layer artificial neural network, *IEEE Int. Conf. on Information, Communication, Instrumentation and Control (ICICIC)*, 1–5.
- Wang, H., Zhang, D., Miao, Z., 2019, Face recognition with single sample per person using HOG-LDB and SVDL, *Signal, Image and Video Processing*, 13: 985–992.
- Wang, J., et al., 2013, Sparse representation for face recognition based on constraint sampling and face alignment, *Tsinghua Sci. Technol.*, 18(1): 62–67.

- Wiskott, L., Fellous, J., Kruger, N., Malsburg, C., 1997, Face recognition by elastic bunch graph matching, *IEEE Trans. Patt. Anal. Mach. Intell.*, 19(7): 775–779.
- Yan, S., Xu, D., Zhang, B., 2007, Graph embedding and extensions: a general framework for dimensionality reduction, *IEEE Trans. Patt. Anal. Mach. Intell.*, 29(1): 40–51.
- Yang, M.H., 2002, Kernel eigenfaces vs. kernel fisherfaces: Face recognition using kernel methods, In: 5th IEEE Int. Conf. on Automatic Face and Gesture Recognition, pp. 215–220.
- Zhong, Y., et al., 2021, HOG-ESRs face emotion recognition algorithm based on HOG feature and ESRs method, *Symmetry*, 13(2): 228.

İnternet Kaynakları

- 1) Nefian, A. V., 1999, Georgia Tech Face Database [Dataset], Center for Signal and Image Processing, Georgia Institute of Technology. Access: http://www.anefian.com/research/face_reco.htm