

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK YÜZ İFADELERİNDEN
DUYGU ANALİZİ

İdil KOÇ

AĞUSTOS 2021

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK YÜZ İFADELERİNDEN
DUYGU ANALİZİ

Hazırlayan
İdil KOÇ

Danışman
Dr. Öğr. Üyesi Kubilay DEMİR

Jüri Üyeleri
Dr. Öğr. Üyesi Selahattin KOŞUNALP
Dr. Öğr. Üyesi Kubilay DEMİR
Dr. Öğr. Üyesi Vedat TÜMEN

AĞUSTOS 2021

ONAY

İdil KOÇ tarafından hazırlanan “**Görüntü İşleme Teknikleri Kullanılarak Yüz İfadelerinden Duygu Analizi**” adlı tez çalışması 19/08/21 tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği/oyçokluğu ile Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Dr. Öğr. Üyesi Selahattin KOŞUNALP
(Başkan)

Dr. Öğr. Üyesi Kubilay DEMİR
(Danışman)

Dr. Öğr. Üyesi Vedat TÜMEN
(Üye)

Bu tezin kabulü, Lisansüstü Eğitim Enstitüsü Yönetim Kurulu’nun .../.../...gün ve .../... sayılı kararı ile onaylanmıştır.

Prof. Dr. Zeki ARGUNHAN
Enstitü Müdürü

BİTLİS EREN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI
ETİK BEYANI

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**Görüntü İşleme Teknikleri Kullanılarak Yüz İfadelerinden Duygu Analizi**” adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 19/09/2021

İdil KOÇ

ÖZET

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK YÜZ İFADELERİNDEN DUYGU ANALİZİ

İdil KOÇ

Yüksek Lisans Tezi

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Kubilay DEMİR

İkinci Danışman: Dr. Öğr. Üyesi Halil YETGİN

Ağustos 2021, 70 sayfa

İnsanlar arası iletişimde büyük rol oynayan yüz ifadeleri duygu, düşünce ve ruhsal durumlarla ilgili bilgi vermede oldukça önemli bir yere sahiptir. İnsanlar arasındaki bu etkileşim gelişen teknolojiyle beraber insan makine ilişkisi içinde kullanılması amaçlanmıştır. Bu sebeple insanlara ait duyguların bilgisayarlar tarafından anlaşılması ve öğrenilmesi oldukça önemli bir konu haline gelmiştir. Birçok alanda yüz ifade analizine ihtiyaç doğduğundan verilerin hızlı işlenip sonucun en büyük doğruluk oranı ile bulunmasını gerektirmiştir. Böylece artan ihtiyaç ve gelişen teknoloji ile bu alanda yapılan çalışmalar da hızla artmıştır.

Bu çalışmada insanın sahip olduğu “öfke, iğrenme, korku, mutluluk, üzüntü, şaşkınlık ve doğal” olmak üzere 7 duygu durumunun analizi gerçekleştirilmiştir. Bu 7 durumun sınıflandırılmasından önce gerçekleşmesi gereken temel adımlar vardır. Temel olarak bu adımlar; yüzün belirlenmesi, görüntünün temizlenip normalize edilmesi, görüntüden özniteliklerin çıkarılması, yüzdeki değişimlerin izlenmesi ve sınıflandırılmasıdır.

Yüz ifadelerinin tespiti amacıyla 35887 adet yüz görselinden oluşan veri kümesinde çalışma yapılmıştır. Bu veri kümesi kullanılarak 7 farklı yüz ifadesi sınıflandırılmıştır. Bu çalışmada gri formatta bulunan 48x48 boyutundaki görseller önermiş olduğumuz CNN modeline uygulanmış ve başarımları değerlendirilmiştir.

Yapılan çalışma da FER2013 veri kümesinde bulunan yüz ifadelerini otomatik sınıflandırmak amacıyla bir evrimsel sinir ağı (CNN) önerilmiş olup, optimizasyon fonksiyonu

olarak da “adam” ve “sgd” optimizasyon fonksiyonları ayrı ayrı denenerek sonuçları elde edilmiştir. “Adam” optimizasyon fonksiyonu kullanılarak önerilen modelde doğruluk oranı %69 olarak elde edilirken “sgd” optimizasyon fonksiyonu kullanılarak önerilen modelde ise doğruluk oranı %92 elde edilmiştir. Böylece önerilen modelde sgd optimizasyon fonksiyonunun doğruluk oranı adam optimizasyon fonksiyonunun doğruluk oranından daha yüksek olduğu belirlenmiştir.

Anahtar kelimeler: Görüntü İşleme, OpenCV, Yüz İfade Sınıflandırılması, Derin Öğrenme, Yapay Sinir Ağları, CNN.



ABSTRACT

EMOTION ANALYSIS FROM FACIAL EXPRESSIONS USING IMAGE PROCESSING TECHNIQUES

İdil KOÇ

Master Thesis

Bitlis Eren University Graduate Education Institute
Department of Electrical and Electronics Engineering
Supervisor: Asst. Prof. Dr. Kubilay DEMİR
Co-Supervisor: Asst. Prof. Dr. Halil YETGİN
August 2021, 70 pages

Facial expressions, which play a major role in interpersonal communication, provide information about emotions, thoughts and mental states. This interaction among people is aimed to be used in human-machine relationships with the advancements of technology. Therefore, understanding and learning human emotions by machines has become a significant issue. However, it is necessary to process facial expressions rapidly and as accurately as possible.

In this study, 7 emotional states of “anger, disgust, fear, happiness, sadness, astonishment and natural” have been analyzed. There are basic steps to be taken before classifying these 7 emotional states, including; determining the face, cleaning and normalizing the image, extracting the features from the image, tracking and classifying the changes in the face.

A study was conducted on a dataset of 35887 facial images to determine facial expressions. Using this data set, 7 different facial expressions were classified. In this study, 48x48 images in gray format were applied to our proposed CNN model and their performance was evaluated.

In the study, a convolutional neural network (CNN) was proposed to automatically classify facial expressions in the FER2013 dataset, and the results were obtained by testing the "man" and "sgd" optimization functions separately as optimization functions. While the accuracy rate was 69% in the proposed model using the "Adam" optimization function, the accuracy rate was 92% in the proposed model using the "sgd" optimization function. Thus, it has been determined that the accuracy rate of the sgd optimization function in the proposed model is higher than the accuracy

rate of the man optimization function.

Keywords: Image Processing, OpenCV, Facial Expression Classification, Deep Learning, Artificial Neural Networks, CNN.



TEŞEKKÜR

Tez çalışmam süresince desteklerini, zamanlarını, yardımlarını ve sabırlarını esirgemeyen bana olan inançları ve koşulsuz sevgileri ile hayatımın her anında yanımda olan çok kıymetli aileme Melek anneme, babam Hilmi ve kardeşim Berksu'ya, yardım ve desteklerini hiç esirgemeyen değerli arkadaşlarım Ali TILFARLIGİL ile Lokman ÇELİK başta olmak üzere diğer tüm değerli arkadaşlarıma,
Teşekkürü borç bilirim.



ÖNSÖZ

Gelişen teknoloji ile beraber bilgisayarla çözülmek istenen problemler de artmıştır. Bunun sonucu olarak da bu sorunlara uygun çözüm önerileri sunulmuş ve teknolojiye çeşitlilik göstererek artmıştır. Bu kapsamda verilerin işlenmesi alanında gelişmeler de hızla artmaktadır. Görüntüyü alıp iyileştiren, iyileştirilen verinin özniteliklerinin çıkaran, öğretip sınıflandırarak anlamlı sonuçlar çıkaran görüntü işleme teknolojileri de hızla artmaktadır. Teknolojideki bu gelişmeler sadece görüntü işleme alanında sınırlı kalmayıp bununla birlikte derin öğrenme alanında da oldukça önemli çalışmalar yapılmıştır.

Geleneksel makine öğrenmesinden farklı olarak ham veri üzerinde çalışan derin öğrenmenin temelleri geçmişe dayanmış olsa da özellikle son yıllarda oldukça popülerdir. Bunun en önemli sebeplerinden biri eğitim için yeteri kadar fazla verinin olması ve bu verileri işleyebilecek donanımsal özelliklerin gelişmiş olmasıdır.

İnsana ait olan özelliklerin bilgisayarlara aktarılması amacıyla yapılan birçok çalışma vardır. Bu çalışmada da görüntü işleme teknikleri ve derin öğrenme ile insana ait olan yüz ifadelerinin sayısal ortama aktarılıp sınıflandırılması yapılmıştır.

İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
ÖNSÖZ	vi
İÇİNDEKİLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SİMGELER DİZİNİ	xii
KISALTMALAR DİZİNİ	xiii
1.GİRİŞ	1
1.1. İlgili Çalışmalar	2
1.2. Sayısal Görüntü İşleme.....	6
1.2.1. Görüntü	6
1.2.2. Görüntü İşleme	7
1.2.3. Uygulama Alanları.....	9
1.2.4. Sayısal Görüntü İşleme Tanımları	11
1.2.5. Görüntü İşleme Teknikleri.....	15
1.2.6. Duygu Analizi	22
2. MATERYAL VE YÖNTEM	24
2.1. OpenCV ve Bileşenleri.....	25
2.2. Haar Cascade	26
2.3. Dlib.....	29
2.4. Makine Öğrenmesi	31
2.4.1. Gözetimli Öğrenme.....	32
2.4.2. Gözetimsiz Öğrenme.....	33

2.5. Yapay Sinir Ağları.....	34
2.5.1. Yapay Sinir Ağları Yapısı.....	34
2.5.2. Yapay Sinir Ağı Modelleri	37
2.5.2.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı.....	37
2.5.2.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı	38
2.5.2.3. Geri Beslemeli Yapay Sinir Ağı	39
2.6. YSA'da Öğrenme	40
2.6.1. Yapay Sinir Ağı Modelleri.....	42
2.6.1.1. Evrişim Katmanı	44
2.6.1.2. Havuzlama Katmanı.....	45
2.6.1.3. ReLU	45
2.6.1.4. Tam Bağlantı Katmanı (Fully Connected Layer)	46
2.6.1.5. Dropout Katmanı.....	46
2.6.1.6. Düzleştirme Katmanı	46
2.6.1.7. Padding İşlemi	46
3. BULGULAR VE TARTIŞMA.....	47
3.1. Yüz İfadesi Tanıma Aşamaları.....	47
3.2. Konvolüsyon Sinir Ağı Yapısı (CNN)	48
3.3. Veritabanı	51
3.4. Eğitim Sonuçları.....	53
4. SONUÇ	57
5. KAYNAKLAR	61
ÖZGEÇMİŞ	70

ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
3.1. Fer2013 Veri Kümesi Eğitim ve Test Veri Sayıları	52
3.2. Veri Kümesindeki İmge Türleri ve Oranları	52
3.3. Etiket ile Duygu Karşılığı.....	53
3.4. Adam Optimizasyon Fonksiyonu Doğruluk Değerleri.....	54
3.5. Adam Optimizasyon Fonksiyonu Kayıp Değerleri	55
3.6. SGD Optimizasyon Fonksiyonu Doğruluk Değerleri	56
3.7. SGD Optimizasyon Fonksiyonu Kayıp Değerleri	56
4.1. Karşılaştırma Matrisi Sonucu	58
4.2. Adam-SGD Optimizasyon Fonksiyonu Doğruluk Oranı Karşılaştırması	59

ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
1.1. Analogdan Sayısala Dönüşüm.....	7
1.2. Elektromanyetik Spektrum	8
1.3. Uygulama Alanları	9
1.4. Kare Izgara Üzerinde Farklı Piksel Boyutlarında Tanımlanan Bir İmaj	11
1.5. Piksel ve Voksel	12
1.6. Çözünürlük Değeri ile İmge Boyutu Arasındaki İlişki	13
1.7. Gri Seviyeli ve İkili Görüntü	14
1.8. RGB Görüntü ve Gri Seviyeli Görüntü	15
1.9. İkili görüntü ve İkili Görüntünün Negatifi	17
1.10. Gri Görüntü ve Gri Görüntünün Negatifi	17
1.11. Nesne Tanıma ve İzleme Adımları.....	22
1.12. Duygu Sınıflandırma Teknikleri.....	23
2.1. Haar-Benzeri Öznitelikler.....	27
2.2. Noktalar Haritası.....	29
2.3. Tipik Çapraz Doğrulama İş Akışının Akış Şeması	31
2.4. Makine Öğrenmesi Sınıfları	32
2.5. Gözetimli Öğrenme	33
2.6. Gözetimsiz Öğrenme	33
2.7. Biyolojik Nöron Yapısı	35
2.8. Yapay Sinir Hücresi	35
2.9. Yapay Sinir Ağı Hücresi.....	36
2.10. Tangent-Sigmoid Fonksiyonu Eğrisi	37
2.11. YSA'nın Genel Yapısı.....	37
2.12. Tek Katmanlı Yapay Sinir Ağı.....	38
2.13. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı	38
2.14. Çok Katmanlı Yapay Sinir Ağı	39
2.15. Geri Beslemeli Yapay Sinir Ağı.....	39
2.16. Evrişimi Tasvir Eden CNN Mimarisi, Havuzlama ve Tam Bağlantılı Katmanlar	42
2.17. Evrişimsel Sinir Ağı Yapısı.....	43
2.18. Evrişimli İşlem Örneği	43

2.19. Evrişim İşlemi	44
2.20. 3 Kanallı Görüntüde 2 Adet 3 Kanallı Filtre ile Evrişim	45
3.1. Haar Cascade Görsel	47
3.2. Genel Akış Diyagramı	48
3.3. Hazırlanan CNN Modeli.....	48
3.4. ReLU Grafiği	50
3.5. İki Tür Havuzlama İşlemi.....	50
3.6. Dropout Katmanında Ağ Yapısı	51
3.7. FER-2013 Veri Kümesi Duygu Örnekler	52
3.8. Adam Optimizasyon Fonksiyonu Kullanılarak Oluşturulan Doğruluk-Devir	54
3.9. Adam Optimizasyon Fonksiyonu Kullanılarak Oluşturulan Kayıp-Devir	55
4.1. Adam ve SGD Optimizasyon Fonksiyonu Kullanılarak Oluşturulan Kayıp-Devir	58
4.2. Farklı Duygulara Göre Yüz İfadeleri.....	60

SİMGELER DİZİNİ

$\mathcal{L}$	Gecikme
W	Ağırlık
δ	Bias Değişkeni, Eşik Değer



KISALTMALAR DİZİNİ

2DPCA	İki Boyutlu Temel Bileşen Analizi
AAM	Aktif Görünüm Modeli
ADC	Analog Dijital Çevirici
API	Uygulama Programlama Arayüzü
BSD	Berkeley Yazılım Dağıtımı
CBS	Coğrafi Bilgi Sistemleri
CNN	Evrişimli Sinir Ağları
CSV	Virgülle Ayrılmış Değişkenler
CV	Bilgisayar Görüşü
FACS	Yüz Eylemlerini Kodlama Sistemi
FAP	Yüz Animasyon Parametresi
FC	Tam Bağlantı Katmanı
GPU	Grafik İşleme Birimi
HMM	Saklı Markov Modeli
IPP	Intel Performans İlkeleri
LDA	Lineer Diskriminat Analizi
MIFS	Karşılıklı Bilgi Özellik Seçimi
MLL	Makine Öğrenimi Kütüphanesi
MLP	Çok Katmanlı Algılayıcı
MR	Manyetik Rezonans
PCA	Temel Bileşen Analizi
PDM	Nokta Dağılım Modeli
ReLU	Rectified Lineer Birim Katmanı
ROI	İlgi Alanı
SOM	Kendini Düzenleyen Harita
YSA	Yapay Sinir Ağları
TPU	Tensör İşleme Birimi

1. GİRİŞ

Veri işleme süreci 4000 yıl önce mağara duvarlarına çizilen hayvan figürlerinden başlayıp günümüzdeki mikroçiplerle devam etmektedir. Bu gelişim binlerce yıl süreyle gerçekleşmiş olsa da son yıllarda teknoloji adına atılan büyük adımlar teknoloji devrim niteliğinde gelişmelere yol açmıştır. Son yıllarda gerçekleşen bu hızlı gelişime en büyük etkenlerden biri de veri işleme hızının artmış olmasına da bağlıdır. Bu gelişmeler neticesinde bilgisayar ile yapılacak işlemlerin sayısı oldukça artmış ve gelişen teknoloji yaşamımızın bir parçası olarak gelişmeye devam etmektedir. Bu sebeple görüntü işleminin kullanım alanlarını sınırlandırmak mümkün değildir. Sağlıktan endüstriye, eğitimden güvenliğe, trafik kontrollerinden savunma sistemlerine kadar birçok alanda aktif olarak yer almaktadır. Bunlara ek olarak gelişen teknoloji ile düşünebilen ve karar verebilen mekanizmaların oluşturulması neticesinde yapay zekâ ve görüntü işleme teknolojileri de geliştirilmiş olup artık makinalar gördüğünü yorumlayarak insani davranışları sergilemektedir. Teknolojideki bu gelişmeler devrim niteliğinde olup hızını kesmeden gün geçtikçe devam etmektedir.

Teknoloji ilerledikçe insanoğlu kendi zekâsıyla yetinemeyip insan gibi düşünen insanı taklit edip yorum yapabilen bu yorumlar neticesinde karar verebilen insandan daha zeki makinalar üretme çabasına girmiştir [1].

Düşünme ve karar vermenin ana kaynağı olan insan örnek alınmış olup makinalar insana benzetilmeye çalışılmıştır. Çünkü insanın sahip olduğu bu özellikler makinalara aktarıldığında birçok problem çözülmüş olup, zamandan ve insan gücünden tasarruf edilmiş olacaktır. Ancak bu özelliklerin makinalara aktarılması ve işlemlerin makinalara yaptırılması kolay değildir. Çünkü en basit işlem için bile makinarya aktarılma sürecinde birçok adım gerekmektedir.

Görüntü işleme temelleri yüzyıllar öncesine dayansa da günümüzde ilerleyen teknolojiyle orantılı olarak görüntü işleme teknolojileri kullanılıp yapılan çalışmalar da hız kazanmıştır. Görüntü işleme teknolojileri birçok alanda kullanılmış olup genellikle araç içi otomasyon, robot uygulamaları, sağlık, biyomedikal, CBS, güvenlik ve askeri alan gibi alanlarda oldukça fazla kullanılmıştır [2].

Görüntü işleme teknolojilerindeki hızlı gelişmeler kullanılan cihazların kapasite ve hızında da önemli gelişmelere sebep olmuştur. Daha yüksek çözünürlüklü ve pikseli görüntüler elde edilmek istenildiğinden buna uygun işlemciler üretilmeye başlanmıştır. Bu görüntüler yüksek veri kapasitesi açığa çıkardığından dolayı kayıt ortamında da önemli gelişmelere sebep olmuştur. Böylece çok farklı kayıt ortamları kullanan cihazlar üretilmiştir [3].

Görüntü işleme alanında yapılan çalışmaların sürekli devam etmesi, donanım

maliyetlerinin düşmesi, birçok alanda kullanılarak hızla kullanım alanının genişlemesi bu alandaki gelişimleri daha da hızlandırmıştır [4].

Yüz ifadeleri kişiler arası iletişimde oldukça önemlidir. İnsanlar arası iletişimde oldukça önemli olan yüz ifadelerinin bilgisayar ortamına taşınması, teknolojinin de gelişmesiyle hız kazanmış olup bu alanda yapılan çalışmalar da artmıştır. Görüntü işleme alanında yapılan çalışmalar içerisinde yüz tanıma teknolojileri oldukça yaygın kullanılmaktadır. Yapılan araştırmalar sonucunda insanlar arası iletişimde yüz ifadelerinin %55 oranla kişinin ses tonu ve kullandığı kelimelerden daha yüksek orana sahip olduğu ortaya çıkmıştır [5].

Yüz ifadeleri insanlar arasında doğrudan anlaşılabilse de bunu makinalara öğretme aşamaları vardır. Makinanın yüz ifadelerini anlayıp sınıflandırabilmesi için ilk olarak yüzdeki biçimsel değişiklikleri ayırt edebilmesi gerekmektedir. Kaş, göz, burun ve dudaklardaki kısa süreli değişimleri tanıyıp bunlara göre kategorilendirebilmelidir. Ancak değişimler kişiden kişiye, ten renginden yaş farklılıklarından kaynaklı problemlere sebep olup öğrenim sürecinde zorluklar çıkabilmektedir [6].

Bu çalışmada insan yüz ifadelerinin 7 temel duygu için sınıflandırılması yapılmıştır. Çalışmada sayısal görüntü işleme hakkında bilgi verilip görüntü işleme tekniklerine değinilmiştir. Ardından çalışmada kullanılan materyal ve yöntemlerden bahsedilip makine öğrenmesi ve yapay sinir ağları alanında açıklamalarda bulunulmuştur. Ardından yüz ifadelerinin tanıtip sınıflandırılması aşamasına kadar gerçekleşen adımlar ile önerilen model ve katmanları hakkında bilgi verilip elde edilen bulgular da karşılaştırılarak çalışma sonuca bağlanmıştır.

1.1. İlgili Çalışmalar

Önceki çalışmalar incelendiğinde yüz ifadelerinin tanınması ile ilgili birçok çalışma yapıldığı görülmüştür. Bu çalışmalara değinecek olursak;

Yüz ifadeleri ile ilgili ilk çalışmalar 19. yüzyıla kadar dayanmaktadır. Günümüzde de popüler bir araştırma alanı olan “Yüz İfade Analizi” çalışmalarının temeli 19. yüzyıla kadar dayanmaktadır. 1872 yılında Darwin’in ileri sürdüğü ve doğuştan gelen bazı duygulardan bahsedilmiş olup böylece yüz ifadelerindeki evrenselliğe değinilmiştir [7]. 1971 yılında Ekman ve Friesen’in yapmış olduğu benzersiz yüz ifadeleri ile ilgili çalışmada ise yüz ifadelerinin her birinin kendine özgü benzersiz altı temel duygu olduğunu belirtmişlerdir [8]. 1978 yılında ise yüz ifadelerini tanımlamak adına yüz eylemlerini kodlama sistemi geliştirilmiştir. Böylece bu sistem ile yüzün yapısına göre değişiklikler belirlenmiş olmaktadır. Her bir kas hareketi için 46 ayrı eylem birimi belirlenmiştir. Bu sistem yüz eylemlerini kodlama sistemi (FACS-Facial Actions Coding

Systems) olarak adlandırılmaktadır [9]. Yüz eylemlerini kodlama sistemi ile yüzde bulunan kasların hareketleri çalışan bir yöntemdir. Bu yöntem ile 7000 ayrı kombinasyon gerçekleştirilmiştir [10].

Yüz ifadelerini kodlama sistemi ilk yapılmaya başlandığında oldukça zaman alıcı işlemlerdi. Bunun sebebi ise tahmin edilen kuralların takip edilmesiyle elle yapılmasından kaynaklı olmasıydı. Ekman ve arkadaşları tarafından başka bir çalışma yapıldı. Bu çalışma ile otomatik bir yüz ifade analiz sistemi önerilmiştir [11]. Yapılan çalışmada oluşturulan veri tabanı 150'nin üzerinde eylem birimi veya kombinasyonunu kullanan 24 ayrı denek ile 1100'den fazla görüntü dizisi içermektedir. Ayrıca görüntülerde bulunan yüz eylemlerini sınıflandırmak için gri seviye görüntülerin temel bileşenler tabanlı bütüncül mekânsal analizi, kırıksıklıklar gibi yerel görüntü özelliklerinin kesin ölçümü ve hareket akışı alanları ile şablon eşleştirme olmak üzere üç farklı yaklaşım karşılaştırılmıştır. Bu çalışmalar sonucunda kullanılan metotlar ile 6 farklı eylem birimi ve 20 denek içeren bir veri kümesi üzerinde, başarımları sırasıyla %89, %57 ve %85 olarak elde edilmiştir. Ayrıca bu üç metodu birlikte kullandıklarındaysa performans %92'lere kadar çıkması sağlanmıştır [12].

Görüntülerdeki yüz ifadelerinin tanınması ve analizi ile ilgili olarak Yacoob ve Davis farklı bir yaklaşım sunmuşlardır [13]. Yapılan çalışma yüzde bulunan temel bölgelerin nitel olarak izlenip yüksek yoğunluktaki eğim noktalarının akış hesaplanması ile yapılmaktadır. Yüz ifadelerinin neden olduğu hareketlerin yönünü belirlemede optik akış hesaplaması kullanılmıştır. Yaklaşımları tek tek nokta hareketlerini izlemekle değil yüzdeki belirli bölgelerin hareket şekillerinin istatistiksel kategorizasyonuna bağlıdır. Bu sebeple yüz özelliklerini içine alan dikdörtgenler için bir bölge izleyici geliştirilmiştir. Her dikdörtgen belli bir özelliği çevrelemektedir. Böylece diğer yüz özelliklerinin hareketleri bölge içindeki akış hesaplamalarına karışmamaktadır [12].

Zaman sıralı veriler ile başa çıkmak ve zaman ölçeği değişmezliğini sağlamak amacıyla Tsapatsoulis ve arkadaşları tarafından Saklı Markov Modeli (HMM) temelli bir yüz ifade tanıma tekniğini önermişlerdir [14]. Önerilen bu teknikte optik akış çıkarımı için kullanılan özellik vektör dizisi sınıflandırmada uygun bir seçim yapabilmek amacıyla Saklı Markov Modeli'nin öğrenme yeteneğinden yararlanmıştır. Bunun yanında duyguların dinamiklerini ve ifadelerin zamanlama karmaşıklığını çözmek amacıyla gözlem bağımlı geçiş matrisiyle Saklı Markov Modeli'ni geliştirmişlerdir. Bu sayede bulanık bir sistem aracılığıyla kararlara açıklık getirmek amaçlanmıştır. Yani sinir ağları ile gerçekleştirilen ifade tanıma sistemi ile yetinmemişlerdir. Yapılan çalışma sonucunda eğitim ve test aşamaları sonucunda %82'lik bir tanıma gerçekleştirilmiştir [12].

1999 yılında iki katmanlı bir algılayıcı mimari içinde özellik tabanlı yüz ifadesi belirleme sistemi Zhang tarafından gerçekleştirilmiştir [15]. Bu yöntem ile yüz ifadelerini tanımlamada yüz görüntülerinden çıkarılan özelliklerin referans noktalarının geometrik konumları ve bu noktalardaki gabor dalgacık katsayıları dizisi kullanılarak gerçekleştirilmektedir. Çok ölçekli ve çok yönelimli Gabor dalgacık katsayıları kullanılarak gerçekleştirilebilmektedir. Görüntülerden çıkarılan özneliklerin bu iki farklı kullanımı birlikte olabileceği gibi birbirinden bağımsız da gerçekleştirilebilir. Gabor dalgacık katsayılarının geometrik pozisyonlara göre farklı türdeki özellikleri tanıma performansında daha güçlü olduğu görülmüştür [12].

Cohen ve arkadaşları yüz ifadelerini otomatik bölütleme ve tanınmasının sağlanması amacıyla yeni bir Saklı Markov Modeli önermişlerdir. Bu modele göre çalışmalarda zamansal işaretler kullanılmış gerçek zamanlı giriş videolarından yüz ifadeleri otomatik olarak tanımaya odaklanılmıştır [16]. Bu çalışma ile yüz ifadelerini bölütleme ve tanınma işlemleri otomatik olarak çok seviyeli Saklı Markov Modeli kullanılarak yapılmıştır. Kişi bağımlı ve kişi bağımsız olmak üzere iki farklı şekilde çalışmanın testleri yapılmış ve beş kişilik bir veri tabanı üzerinde kişi bağımlı test için daha yüksek tanıma oranı başarıları sağlanmıştır [12].

Göktürk ve arkadaşları görünüm bağımsız etkili bir yöntem önermişlerdir. Bu yöntem yüz ifadelerinin tanınmasında varsayıma dayalı olmayan, görünüm-bağımsız bir yöntemdir [17]. Bundan önce yapılan çalışmalar incelendiğinde çalışmaların çoğunda kamera karşısında bulunan kişinin sadece 3D kafa pozisyonu değişmediğinde yüksek başarılı tanıma gerçekleştirilmiştir. Göktürk ve arkadaşları ise önerdikleri yöntem ile görüntü dizisinin her karesinde yüzün şekil ve pozisyonunu eş zamanlı olarak elde etmek amacıyla yeni bir 3D model tabanlı izleyici kullanılmaktadır. Böylece baş hareketlerindeki dönmelere rağmen 3D izleme özelliği sayesinde 3D bilgiler çıkarılmaktadır. Ayrıca Destek Vektör Makineleri'nin (SVM) sınıflandırması yapılırken uygun bir metot olduğu anlaşılmıştır. Sonuç olarak sınıflandırma yapılırken %91'lik bir başarı ile tanıma gerçekleşmiştir [12].

Silva ve Hui'nin önerdikleri yöntemde yüz özelliklerinin yerel hareket vektörlerini hesaplamak amacıyla kenar sayma ve görüntü korelasyon optik akış teknikleri kullanılmıştır. İnsandaki duygusal durumun belirlenmesinde ise sinir ağı kullanılmaktadır. Bu çalışmada çevrimdışı hesaplamalarda kullanılan teknikler gerçek zamanlı uygulamalarda kullanılması amaçlanmıştır [18].

Feng ve arkadaşlarının önerdiği yöntemde ilk olarak yüz görüntülerini etkin bir şekilde ifade etmek amaçlanmıştır. Bunun için Yerel İkili Örüntü operatörü kullanılmıştır. Ardından yüz ifadelerini sınıflandırmak amacıyla Lineer Programlama tekniği kullanılmıştır. Sınıflandırmada yedi farklı yüz ifadesi kullanılmıştır. Japon kadın yüz ifadelerinin olduğu veri tabanında ortalama

%93.8'lik başarı oranıyla tanıma gerçekleştirilmiştir [19].

Lajevardi ve Lech'in önerdikleri sistemde görüntüler üzerinde yüz tanıma modülü Haar-like özellikleri ve AdaBoost algoritmasına dayanmakta olup, yüz tanıma işleminden sonra görüntüler arasında bilgiler kullanılarak duygu yoğunlukları çıkarılarak elde edilmektedir. Seçilen karelerde MIFS algoritması kullanılır. Gabor filtreleme ile karakteristik özellikler çıkarılmaktadır. En son adımda da NB sınıflandırıcı ile sınıflandırma yapılmaktadır. Cohn Kanade veri tabanı kullanılarak optimize olmayan özellikler için %68.9, optimize özellikler ile de %79.5 doğruluk oranı ile test gerçekleştirilmiştir [20].

Martins ve arkadaşlarının yüz ifadesi tanıma amacıyla önerdikleri yöntemde, ilk olarak Aktif Görünüm Modeli (AAM) ile insan yüzü tanımlanmaktadır. Ardından farklı ifadeleri kategorilendirmek amacıyla Lineer Diskriminant Analizi (LDA) kullanılır. Yüz ifadelerini sınıflandırmada ise Mahalanobis mesafesi esas alınmıştır. Aktif Görünüm Modeli ile eğitim görüntü kümesinde gözlemlenen şekil ve doku değişimleri temsil edilmektedir. Sınıflar arasındaki ayırt edilebilirliği, farkı en yüksek düzeye çıkaran en belirgin özellikleri elde edebilmek amacıyla Lineer Diskriminant Analizi kullanılmaktadır [21].

Doku özelliklerinin çıkarılması ile cilt deformasyonu ile ortaya çıkan görüntü yoğunluk değişiklikleri belirlendiğinden video tabanlı yüz tanıma sistemlerinde doku özellikleri oldukça fazla kullanılmaktadır. Ancak mevcut doku özelliklerinde aklık derecesi ve aydınlatma ile ilgili sorunlar olabildiğinden bu sorunları çözmek amacıyla Song ve arkadaşları görüntü oran özellikleri adı verilen yeni bir doku özelliği önermişlerdir. Ayrıca yüz ifadesi tanıma doğruluğunu artırmak amacıyla yüz özellik noktalarının geometrik hareketlerini açıklayan yüz animasyon parametrelerini (FAP-Facial Animation Parameter) görüntü oranı özellikleri ile birleştirmişlerdir. Önerilen bu yöntem daha önce önerilen doku özellikleri ile karşılaştırıldığında aklık derecesi ve aydınlatma ile ilgili sorunlara karşı daha güçlü olduğu belirtilmiştir. Ayrıca asimetrik yüz ifadeleri işlemede de etkili bir yöntem olduğu belirtilmiştir [22].

Oliveira ve arkadaşları yüz görüntülerinden özellik çıkarımı için İki Boyutlu Temel Bileşen Analizi (2DPCA) yöntemini kullanmış olup bu yöntemde geleneksel Temel Bileşen Analizi (PCA) yönteminden farklı olarak tek boyutlu vektörler yerine iki boyutlu matrisler kullanılır. İki Boyutlu Temel Bileşen Analizi ile ayırt ediciliği oldukça yüksek özellikler sağlanmaktadır. Ancak burada gereksiz katsayıların maliyeti ortaya çıkmaktadır. Katsayıların analiz edilip gereksiz olanların çıkarılması amacıyla çok amaçlı genetik algoritmaya dayalı bir özellik seçim algoritması ile katsayıları büyük ölçüde azaltmış ve tanıma oranını da artırmıştır. Özellik seçim algoritmaları ile Temel Bileşen Analizi yönteminin etkinliğini göstermek amacıyla k-En Yakın Komşular ve Destek Vektör Makinesi olmak üzere iki farklı sınıflandırıcı kullanılmış olup sırayla başarı oranları

ise %91 ile %94 elde edilmiştir [23].

Farahani ve arkadaşları bulanık tabanlı yeni bir yöntem önermişlerdir. Bu yöntemde farklı yaş gruplarındaki göz ve ağız özellikleri ile duygu tanınması yapılması amaçlanmıştır. Farklı renk alanlarının birleşmesiyle gözler ve ağız algılanır. Ardından Mamdani yöntemi ile yüz özellikleri ve bunların duygu uzayındaki karşılıkları belirlenir. Bu yöntem ile Ebner'in yüz ifadesi veri tabanı üzerinde ortalama %78.8 doğruluk oranı ile sonuçlanmıştır [24].

Yüz ifadesi tanımada kenar algılama algoritmasına dayalı bir yöntem Chen ve Cheng tarafından önerilmiş ve kullanılmıştır. Bu çalışma ile ten rengi modeli ile kenar şekil özellikleri belirlenmiştir. Kenar belirlemede yaygın olarak kullanılan Canny, Laplace, Sobel ve Robert operatörleri karşılaştırıldığında Canny operatörü kenar belirlemede karmaşık, Robert operatörü basit, Laplace ve Sobel operatörleri ise belirsiz olduğu ortaya çıkmıştır. Sistem JAFFE veri tabanı kullanılarak eğitilip test edildiğinde en yüksek değerler Canny operatörü ile elde edilmiştir [132].

Yüz ifadesi tanıma sisteminde katmanlı kodlama kaskad optimizasyon modelini Neoh ve arkadaşları kullanmış ve bu sistem üzerinde çalışmışlardır. Duygu tanıma başarısının yüksek olmasında etkili bir yüz gösterimi oldukça önemlidir. Bu sebeple çalışmalarında ilk olarak geliştirilmiş Yerel Gabor İkili Desen operatörünü yüz temsili ile elde etmek amacıyla kullanmışlardır. Doğrudan Benzerlik ve Pareto-Tabanlı Özellik Seçimi algoritmaları önerilmiştir. Pareto-tabanlı özellik optimizasyonunda her bir ifade kategorisi en iyi şekilde ifade edilir ve diğer ifadeler ile en belirgin farklar ortaya koyan özellikler üzerinde durmaktadır. Yedi farklı yüz ifadesinin tanınması için sinir ağı ve topluluk sınıflandırıcı teknikleri kullanılmıştır. Cohn-Kanade veri tabanı kullanılarak değerlendirildiğinde doğrudan benzerlik tabanlı optimizasyon için %96,8 ve Pareto-tabanlı özellik seçimi için %97,4 doğruluk oranı ile başarıya ulaşmıştır [133].

1.2. Sayısal Görüntü İşleme

1.2.1. Görüntü

Görme özelliğine sahip tüm canlılar yaşam var olduğu sürece cisimlerden yansıyan sinyalleri işleyerek görme eylemini gerçekleştirmişlerdir. Teknolojinin ilerlemesiyle insanların sahip olduğu bu özellik bilgisayarlara da aktarılmaya başlamıştır. Artık analog olan görüntüler dijital hale getirilip işlenip saklanabilmektedir.


Birçok tanıma sahip olan görüntünün en anlaşılır tanımlarından biri de ışık olayları sonucu elde edilen nesne biçimidir denilebilir. Görüntüyü $a(x,y)$ şeklinde tanımlayacak olursak x,y resmin koordinatlarını belirtirken a ise şiddet birimini ifade edebilir [3].

Belli bir alan veya çerçeve içerisinde tanımlanmış olan bu fonksiyonu, bilgisayar biliminde video görüntüsü dijital görüntü veya resim olarak adlandırılabilir. Görüntünün birçok alanı ve oldukça geniş bir kapsamı bulunmaktadır. Cisimden yansıyan ışığa görüntü denildiği gibi vücut ısı da x-ışınları ile görüntüleme yapılırken kızılötesi görüntülemelerle de ısı değerleri gözlemlenebilir [26].

Analog görüntü; görme sistemlerimizle algıladığımız zamanda sürekliliği olan sayısal olarak ifade edilemeyen görüntüler olarak ifade edilir. Süreklilikleri olduğundan belirli aralıklarda tüm değerleri alabilirler [36].

Dijital görüntüde ise analog görüntüdeki gibi sinyaller sürekli değildir. Analog görüntüler herhangi bir elektronik cihazdan alınır ve sayısallaştırılır. Burada sinyaller ayrık zamanlıdır [36].

Bir cisim tarafından yayılan analog sinyal bir sensör (ADC) veya cihazla alınarak işlenip sayısal sinyale dönüştürülür. Dijitale dönüştürülmüş olan görüntü sayısal haliyle kaydedilip saklanır [37]. Aşağıda da gösterildiği gibi kameradan alınan analog görüntü sayısallaştırıcı kullanılarak sayısal görüntüye dönüştürülmektedir.




Şekil 1.1. Analogdan Sayısala Dönüşüm

1.2.2. Görüntü İşleme

Hızla ilerleyen teknoloji, gelişen bilgisayar sistemleri ve artan hız kapasiteleri neticesinde insanoğlunun teknolojiyi kullanarak yapmak istedikleri de artmıştır. Bunun en güzel örneklerinden biri de görüntü işleme teknolojileridir. Bu alanda yapılanlar ve ilerlemeler her geçen gün artmıştır. Görüntü üzerinde yapılan incelemeler ve işlemler gelişen teknolojiyle doğru orantılı olarak

artmaktadır. Son 40 yılda bilgisayar boyutlarındaki küçülme ve bellek kapasitelerindeki artış, veri işleme alanında oldukça fazla gelişmelere sebep olmuştur.

Görüntü işleme teknolojileri temelinde insanın görme eylemini gerçekleştirirken uygulanan adımlara benzer. İnsanların görme eylemi incelendiğinde görmek için göz ve gözün gördüğü cisimleri anlamlandırmak için merkezi sinir sistemi bulunmaktadır. Bu alandaki ilerlemeler kaydedilirken insanın görme sistemi örnek alınmıştır. İnsandaki göz donanımı, yapay sinir sistemi de yazılımı temsil ettiği düşünülebilir. Yani görme, gördüğünü algılama ve ayırt edebilme sırayla gerçekleşen bir dizi işlemdir. Bu insan sisteminde olduğu gibi bilgisayar teknolojilerinde de gerçekleşir.



Şekil 1.2. Elektromanyetik Spektrum [128]

İnsan göz organıyla cisimleri görüp beyni ile bunları algılayabilir. Bu analog temelli çalışmaya dayanan bir sistemdir. İnsan görme olayından hareketle kameradan cismin görüntüsü alınıp görüntü işleme teknolojileri ve yapay sinir ağları ile alınan görüntü işlenip yorumlanabilir. Bilgisayarlarda da görüntünün alınırken bilgisayar sistemine uygun halde alınması gerekmektedir. Analog görüntünün bilgisayar sistemine uygun hale getirilmesi işlemine sayısallaştırma denilir. Sayısallaştırma işlemi birçok farklı teknikle yapılabilir. Analog bir verinin sayısal hale dönüştürülmesine sayısallaştırma adı verilir [27].


Görüntü işleme özet olarak analog görüntünün sisteme alınıp üzerinde işlemler yapılarak sayısallaştırılması sayısallaştırılan verinin analiz edilip işlenmesi sürecini kapsar.

Görüntü işleme yapılırken ön hazırlık evresi bulunmaktadır. Bu ön hazırlık evresi görüntüdeki gürültüyü azaltmak için yapılır. Görüntüdeki gürültüye bulanıklık örnek verilebilir.

Ön hazırlık evresi düşük, orta, yüksek seviye olmak üzere üç işlemle gerçekleştirilir. Düşük seviyedeki işlemler filtreleme ile orta seviyedeki işlemler nesnelerin tanınması yüksek seviye işlemler ise analiz işlemlerini gerçekleştirmeyi sağlar. Böylece görüntü alınıp içeriği analiz edilmiş olur. Bu adımlar neticesinde görüntü işleme gerçekleştirilmiş olur [2].

1.2.3. Uygulama Alanları

Gelişen teknolojiyle beraber görüntü işlemenin sağladığı faydalar artınca bu alanda kullanılan teknikler de artmıştır. Kullanılan farklı teknikler görüntüden görüntüye ve amaca göre değişkenlik göstermektedir. Tüm görüntü işleme tekniklerinin özünde analogdan sayısala dönüştürme işlemi bulunmaktadır. Bu alanda yapılan çalışmalar birçok sektörde uygulanmakta ve bu alandaki çalışmalar hızla artıp uygulama alanları da genişlemektedir. Birçok uygulama alanına sahip bu teknoloji tıptan astronomiye mühendislikten endüstriyel uygulamalara kadar birçok alanda yaygın olarak kullanılmaktadır. Bu alanlara özet verecek olursak; tıp, astronomi, coğrafya, biyoloji, yüz tanıma ve analizi, elektronik, mimari, tasarım, gıda gibi birçok alana yayılmış durumdadır. Görüntü işlemeyi birkaç alanla sınırlamak mümkün değildir. En yaygın kullanıldığı uygulama alanlarından birkaçı aşağıdaki görselde belirtilmiştir.



Şekil 1.3. Uygulama Alanları

Görüntü işleme teknolojisi tıp alanında oldukça yaygın kullanılmaktadır. Tıbbi görüntülerin incelenmesi ve organların görüntülenmesi sonucu tıpla teknoloji birleştirilmiş olup sağlık alanında oldukça fazla gelişmeler yaşanmıştır. Stasiek vd. nin gerçekleştirdiği çalışma ile hastalıklı bölge üzerinde görüntü işleme teknolojisini kullanarak ve ilgili alana ısı sıvı kristalleri uygulanarak bölgedeki sıcaklık farkları bulunmuştur [29]. Tıpta görüntüleme amacıyla en çok kullanılan yöntemlerden biri de MR yöntemidir [30]. MR, Manyetik Rezonans'ın kısaltmasıdır. Bu yöntemle canlıların iç yapısı görüntülenebilmektedir. Bu yöntem sayesinde tümör, kırıklar, katarakt gibi göz hastalıkları teşhis edilebilir [31].

Görüntü işleme teknolojileri ile görüntülerin anlık olarak incelenip yorumlanması, savunma ve güvenlik alanlarında da bu teknolojinin kullanımını sağlamıştır [2]. Askeri alanlarda kullanımı da oldukça yaygın olan bu teknoloji ihtiyaca göre farklı şekillerde kullanılabilmektedir. Örneğin termal kameralar kullanılarak asgari alanda birçok güvenlik önlemi alınabilmektedir. Termal kameralar bir cismin sıcaklık soğukluk bilgilerini ölçebilen cihazlardır. Normal kameralardan farkı, görüntüyü ısı ile oluşturabilmesidir [33]. Termal kameralar nesne tanımlama ve keşif yapabilme özelliklerinden dolayı askeri alanlarda oldukça fazla tercih edilmektedirler.

Güvenlik amacıyla kullanılan yöntemler de zaman geçtikçe artmaktadır. Bunlara örnek olarak parmak izi tanıma, yüz tanıma, iris tanıma uygulamaları yapılmıştır. Parmak izi tanıma sisteminde ilk olarak parmak izi okuyucu ile görüntü alınır ve alınan görüntü üzerinde işlemler yapılır. Yüz tanıma sisteminde de benzer yöntemler uygulanır. Özetleyecek olursak ilk olarak yüz görüntüsü alınıp görüntülerden temizlenir. Görüntü işleme aşamasına geçmek için ön hazırlıklar yapılmalıdır. En son aşamada da karşılaştırma yapıp görüntünün eşleştiği isim belirlenmiş olur. Bu sistemlerin güvenlikten personel takibine birçok avantajı bulunmaktadır. Ve birçok sektörde bu sistemlerin kullanımı oldukça yaygındır.

Görüntü işleme teknolojilerinin uygulama alanlarını sınırlandırmak mümkün değildir. Uygulama alanlarından kısaca söz edip özetleyecek olursak tıpta, savunma ve güvenlik alanlarında kullanıldığı gibi daha birçok alanda da uygulama alanına sahip geniş bir yelpazesi bulunmaktadır. Örneğin; astronomi alanında uydu fotoğrafları ile gezegenlerin birçok fotoğrafı alınıp işlenebilmektedir. Bu sektörde görüntü işleme teknolojileri oldukça fazla öneme sahiptir. Ayrıca plaka tanıma sistemleri ile araçların giriş çıkış kontrolleri, otomatik geçişler, kara listede araç kontrolleri ve raporlama yapılabilmektedir. Böylece otoparka giriş/çıkış noktaları kontrol altına alınmış olup istemediğimiz araçların girmesini bu yöntemle engellemiş oluruz.


Endüstriyel uygulamalarda da görüntü işleme teknolojisinin yeri oldukça önemlidir. Toplamda 200'den fazla kumaş hatası bulunmaktadır. Bu hataların 40-50 tanesi kalite kontrol

kartlarında bulunmaktadır [34]. Bu hatalardan bazıları leke, ip kaçığı, delik hatası vb. gibidir. Bu hatalar insan tarafından kontrol edilince insani kusurlardan dolayı örneğin yorgunluk, dikkatsizlik gibi sebeplerden dolayı hata bulmadaki verim az olacaktır. Bu konuda verimi artırmak için gelişen teknoloji kullanılıp, görüntü işleme teknolojileri ile bu verim artırılmıştır. Örneğin tekstil sektöründe hatalı kumaş ayıklaması yapmak için de görüntü işleme teknolojileri kullanılmaktadır. Kamera ile kumaş görüntüleri alınıp gerekli işlemler yapılır ardından görüntüler üzerinde çıkarımlar yapılarak hatalı görüntüler elde edilir ve hatanın türüne göre sınıflandırma yapılır [35]. Görüntü işleme teknolojilerinin en genel kullanıldığı düşünülen birkaç alan örneklenmiştir. Bu örnekleri artırmak mümkündür. Çünkü bu teknolojinin kullanım yelpazesi oldukça geniş olduğundan birkaç alanla sınırlandırılması mümkün değildir.

1.2.4. Sayısal Görüntü İşleme Tanımları

Piksel resim ögesi anlamına gelmektedir. Pikseller bilgisayarlarımızın ve diğer cihazlarımızın ekranlarını oluşturan en temel bileşenler olup ekrandaki görüntülerde milyonlarca pixel bulunabilir [38]. Milyonlarca pikselin tek görselde bulunması ve çok küçük olmalarından dolayı biz ekrana bakınca pikselleri göremeyiz. Ancak görüntüyü çok yakınlaraştırırsak o zaman pikselleri fark edebiliriz [39].


Piksel bir görüntünün en temel bileşeni olup, $m \times n$ boyutlu piksellerden oluşan matrise görüntü adı verilmektedir [40]. “m” satır sayısı, “n” sütun sayısını ifade edecek olursa satır ve sütun sayılarının çarpımıyla oluşan matris görüntüyü oluşturmaktadır. Bu görüntüde pikseller 2 boyutlu dikdörtgen ızgara üzerine yerleşmiş şekilde bulunmaktadır [41]. Aşağıdaki görselde kare ızgara üzerinde farklı piksel boyutlarında tanımlanan görüntü sırasıyla 3×4 , 12×16 , 48×64 ve 192×256 şeklindedir.



Şekil 1.4. Kare Izgara Üzerinde Farklı Piksel Boyutlarında Tanımlanan Bir İmaj [44]

Bir pikselin 3 boyutlu karşılığı “voksel” olarak adlandırılır. Pikselde bulunan satır ve sütun değerine derinliğin de eklenmesiyle voksel oluşmaktadır. Derinlik kavramı eklendiğinden dolayı voksellere piksellerin hacimsel hali denilebilir. Vokselleri 3 değişkenle belirtecek olursak $m \times n \times k$ formülünde m satır, n sütun, k ise derinliği ifade eder [41].

Vokseller tıp alanında tomografi cihazlarında MR cihazlarında, X-Ray’lerde kullanılır. Böylece insan vücudunun 3D modelleri elde edilir. Bilgisayar oyunları oluştururken de voksel görüntüleme kullanılmaktadır [42].



Şekil 1.5. Piksel ve Voksel [25]

Görüntüyü oluşturan piksellerin santimetre başına düşen sayısına çözünürlük denilir. 1 inç 2.54 cm ye eşittir. Çözünürlüğü cm veya inç başına düşen piksel sayısı ile bulabiliriz. Bir piksel $m \times n$ ile gösterilir m satır n ise sütun sayısıdır. Çözünürlük toplam piksel sayısı ile ilgili olduğundan dolayı bu formülden yola çıkarak çözünürlüğü toplam satır ve toplam sütun sayısının çarpımı olarak ifade edebiliriz [36]. Yine aynı formülden yola çıkarak piksel sayımızın artmasıyla yani $m \times n$ sonucunun artmasıyla çözünürlükte doğru orantılı olarak artacaktır.

Bir görüntüde çözünürlüğü göstermek için örnekleme frekansı kullanılır. Örnekleme frekansı ile çözünürlük doğru orantılıdır. Görüntüde çözünürlük bilgisini göstermek için Dot Per Inch (DPI) kullanılmaktadır. 400×500 dpi çözünürlükteki görüntüde en 400, boy 500 olup çözünürlüğü $400 \times 500 = 200000$ olmaktadır [43].



Şekil 1.6. Çözünürlük Değeri ile İmge Boyutu Arasındaki İlişki

Sayısal görüntü işlemede histogram kavramı sayısal görüntünün grafiksel gösterimi olarak adlandırılır. Grafik görüntüdeki tonlar, piksel sayısına göre çizilir. Histogram, tonların dağılımını tespit etmek amacıyla kullanılabilir. Grafikte yatay ve dikey eksen bulunmaktadır. Yatay eksen ton çeşitleri için dikey eksen de piksel sayılarını göstermek için kullanılır. Böylece görüntüler analiz edilmiş olur. Görüntünün parlaklığı ve kontrastı, histogram ile ayarlanabilir. Ayrıca görüntü eşitleme ve görüntü eşikleme işlemlerinde de histogramdan yararlanılır [44].

Histogram grafiğinde 0'dan 255'e kadar renk ağırlık değerleri bulunmakta olup 0'dan 255'e doğru renk yoğunluğu koyudan açığa doğru olmaktadır. 0 en karanlığı 255 ise en açığı temsil eder. Renkli görsellere ait histogram grafiklerinde ise R (Red), G (Green) ve B (Blue) bileşenleri için ayrı ayrı üç histogram grafiği elde edilir [43].

Bir görüntünün oluşabilmesi için en önemli kavramlardan biri ışıktır. Işığın enerjisi ile renkler elde edilir. Teknolojinin gelişmesiyle rengi oluşturan bu ışıksal enerjinin elektronik ortamlara aktarımı sağlanmaya başlanmıştır [36].

Doğada bulunan her rengin elektronik ortamda bir kodu mevcuttur. Bu kodlar dijital renk uzayları tarafından elde edilmektedir [46].

Görüntüyü oluşturan her bir pikselin R (Red), G (Green) ve B (Blue) olmak üzere üç farklı bileşeni bulunmakta olup her bir bileşen 0-255 arasında değer almaktadır. Herhangi bir rengi dijital ortamda gösterebilmek için bu üç rengin farklı yoğunluklarda karışımları ile istenen renk elde edilir [45].

Bilgisayar grafiklerinde, baskı aletlerinde, video sistemlerinde birden çok renk uzayı tercih edilmekte olup bilgisayar grafiklerinde en çok RGB renk uzayı kullanılmaktadır. Yani farklı renk uzayları kullanılacak ortama göre tercih edilmelidir [36].

RGB adını Red, Green, Blue kelimelerini baş harflerinden almaktadır. RGB temelinde üç ana rengi bulundurmaktadır. Bunlar kırmızı, yeşil ve mavi renkleridir. Diğer tüm renkler bu temel renklerin belirli oranlarda karışımıyla oluşmakta olup tüm renklerin karışımıyla beyaz rengi elde edilmektedir. Yani beyaz tüm renkleri içermektedir [43].

Bir objenin analog görüntüsünün elektronik bir cihazla alınarak dijitalleştirilmesiyle ayrık sinyaller haline getirilen dijital görüntüler oluşturulur ve böylece sayısal görüntüler elde edilmiş olur [47]. $f(x,y)$ biçimiyle ifade edilen matriste x ve y koordinatları belirlerken f ışık yoğunluğunu ifade etmektedir. Görüntüler bu şekilde oluşmaktadır. Matris halinde bulunan sayısal görüntüler üçe ayrılmaktadır. Bunlar; ikili görüntü, gri seviyeli görüntü ve renkli görüntüdür [47].

İkili görüntü sadece siyah ve beyaz piksellerden oluşan bir görüntü çeşidi olup beyaz 1, siyah ise 0 değeri ile gösterilmektedir [47]. Görüntü işleme teknikleri kullanılırken gri ve renkli görüntüler ikili görüntüye çevrilmektedirler. Aynı özneliğe sahip alanların belirlenmesi için uygulanan yöntemlerden biri de görüntüyü ikili görüntüye çevirmektir [36]. İkili görüntülerde sadece iki olası gri düzeyi vardır. Bu nedenle piksel sadece bir bitle ifade edilir. Değeri ya sıfırdır ya da birdir. Yani ya siyahtır ya da beyaz. Başka bir olasılık bulunmaz. İkili görüntüler çeşitli şekillerde ortaya çıkabilirler ama genelde gri seviyeli görüntülerden oluşmaktadırlar [48].



Şekil 1.7. Gri Seviyeli ve İkili Görüntü

Siyahtan beyaza kadar ışığın yoğunluk bilgisine göre gri tonlamalar elde edilir. Grinin birçok düzeyi vardır. Gri seviye genelde 8 bitle ifade edildiğinden 0-255 e kadar değer almaktadır [49]. Bir görüntüdeki pikseller 0-255 arasında değer almakta olup beyaz 1 siyah 0 değerini aldığından 1'den 254'e kadar olan değerler gri seviye renkleri göstermektedir. Satır ve sütunu

içeren iki boyutlu matrise ilave olarak bir boyut da renk ifadesi için bulunmaktadır. Her bir katmanda 1 piksel 1 byte olduğundan renkli görüntülerde $3 * 8 = 24$ bit ile ifade edilmektedir [36]. (0,0,0) siyahı temsil ederken (255,255,255) beyazı temsil etmektedir. Piksel başına alınan bu üç değer ışığın yoğunluğunu ve rengini belirtir. Aşağıdaki görüntüde gri seviyeli ve RGB görüntüler bulunmaktadır.



Şekil 1.8. RGB Görüntü ve Gri Seviyeli Görüntü

1.2.5. Görüntü İşleme Teknikleri

Görüntü işleme yapılırken uygulanan yöntemler konudan konuya göre farklılık göstermektedir. Görüntü işlemenin yapılabilmesi için görüntüyü alacak bir donanımsal cihaza ihtiyaç vardır. Görüntü, bu cihazlarla alındıktan sonra amaca göre işlemler yapılmaktadır. Alınan analog görüntü sayısallaştırılır ve sayısallaştırılan görüntü bir dizi işlemten geçirilerek işlenip yorumlanır. Bu işlemlere örnek olarak görüntü onarma, görüntü sıkıştırma, görüntü bölütleme verilebilir [3].

Görüntü işleme yapılırken görüntü, görüntüyü alabilecek donanımla alınır. Alınan analog görüntü bir ADC sensörüyle dijitale çevrilir. Sayısal hale dönüştürülmüş olan görüntüde parlaklık ayarlanması, gürültülerin temizlenmesi, görsellerin ayrıştırılması gibi ön işlemlerden geçirildikten sonra görseldeki bölgeler istenen şekilde birbirinden ayrıştırılır. Birbirinden ayrıştırılan görsel bölümlerinde son olarak tanıma ve yorumlama aşaması gerçekleştirilir. Her görüntüde amaca uygun olarak görüntü işleme yapacak yazılımlar ve donanımlar tercih edilir [3].

Görüntü işleme üzerinde yapılan bu işlemleri üç başlık altına alırsak, görüntünün alınıp temel işlemlerin uygulanması düşük seviye işlemlerken, bu işlemler gerçekleştirildikten sonra

görüntüyü daha küçük parçalara ayırıp anlamlar çıkarma işlemleri orta seviye işlemleri ve yorumlama ile karar aşamasını gerçekleştirip gruplandırma yapan en son işlemler yüksek seviye işlemler olarak tanımlanabilir [36].

Görüntü iyileştirme, görüntünün alınıp temel işlemlerin uygulanması olan düşük seviye işlemlerinden biridir. Görüntü iyileştirme yapılarak daha net ve kaliteli sonuçlar çıkarılır. Parlaklık, karışıklık, eşikleme, görüntü negatifi, filtreleme işlemleri gibi işlemler görüntü iyileştirme kapsamında değerlendirilebilir. Bu işlemler uygulanırken yeterli seviyede veriye sahip olunması sonucu etkilemektedir [36].

En önemli piksel özelliklerinden biri parlaklık birçok görüntü düzenleme algoritmasında yer almaktadır. Şu ana kadar parlaklık hesaplamaları için geleneksel bir formül bulunmamakta olup aynı görüntü işleme aracı ile birbirinden farklı parlaklık ölçüleri kullanılabilir. Öte yandan parlaklık ölçülemeyen psikofiziksel bir özellik olarak karşımıza çıkmaktadır. Sayısal görüntü işleme için de oldukça önemli bir parametre olup parlaklık hesaplamaları için formüller gerekmektedir. Bu sebeple parlaklık hesaplamaları için genel bir formül olmayıp birden fazla farklı formül kullanılabilmektedir [51].

Sıfırdan büyük ve küçük değerler kullanılarak parlaklık değeri değişmektedir [36]. Bunu formül üzerinde gösterecek olursak;

$$g(x, y) = f(x, y) + b \quad [36] \quad (1.1)$$

Bir görüntüdeki parlaklık değerleri arasındaki farka karışıklık (contrast) denilmektedir. Bu farkı, görüntüdeki maksimum ve minimum piksel yoğunluğu olarak da ifade edebiliriz [52]. Görüntüler arasındaki fark karışıklıkla belirlendiğinden bunun ayarı oldukça önemlidir. Görüntü analog olarak alındığında çevresel ve donanımsal birçok sebepten dolayı görüntüde veri kayıpları oluşmaktadır. Bu nedenle görüntü iyileştirme ayarlarının oldukça hassas ve doğru yapılması gerekmektedir [36]. Karışıklıkla ilgili formül;

$a < 0$ veya $a > 0$ olmak üzere;

$$g(x, y) = a * f(x, y) \quad [36] \quad (1.2)$$

Görüntünün daha kolay analiz edilmesini sağlamak amacıyla görüntünün piksellerini değiştirdiğimiz bir yöntem olan eşikleme işleminde renkli veya gri tonlu olan görüntüler sadece siyah beyaz görüntüye dönüştürülür. Siyah beyaz görüntüye dönüştürme işlemi olduğundan bu

işleme ikili görüntüye dönüştürme işlemi de denilebilir. Görüntüde odak noktasının seçilip geri kalan kısımlarını yok saymak için de bu yöntem kullanılabilir [53].

Sayısal görüntü işlemede kullanılan bu teknikle görüntüler bölümlere ayrılıp gri tonlama eklenir. Ardından bu görüntü ikili görüntüye dönüştürülür. İkili görüntü oluşturmak için bu teknik tercih edilmektedir [28].

Bir görüntünün negatifi, görüntünün orijinal halindeki piksel yoğunluğunun tersini ifade eder. En koyu piksellerin en parlak hale gelmesi, en parlakların da en koyu hale gelmesi işlemine negatifleştirme denilmektedir. Görüntünün negatifini bulabilmek için, her bir pikselin maksimum yoğunluk değerinden çıkarılması gerekmektedir. Örnek verecek olursak; 8 bitlik gri tonlamalı bir görüntünün negatifini bulmak için her pikseli 255'ten çıkarırız [54].



Şekil 1.9. İkili görüntü ve İkili Görüntünün Negatifi



Şekil 1.10. Gri Görüntü ve Gri Görüntünün Negatifi

Görüntü üzerinde çevresel faktörlerden kaynaklanan gürültüler bulunmaktadır. Bu gürültüler, görüntü kalitesinin ve sinyallerin bozulmasına sebep olduğundan görüntü üzerinde yapılacak işlemlerde olduğu gibi analiz uygulamalarındaki başarıyı da etkilemektedir. Bu gürültüleri azaltma yöntemlerinden biri de filtreleme yöntemleridir. Filtreleme işlemlerini frekans düzleminde ve uzaysal düzlemde yapılan filtrelemeler olarak iki başlık altına alabiliriz [55].

Görüntü filtrelemede amaç sadece görüntüleri gürültüden temizlemek olmayıp görüntüdeki verileri de korumak oldukça önemlidir. Filtreleme işlemleri görüntüdeki gürültüyü azaltırken gürültü olmayan piksellerin de yoğunluk değerinin değişmesine sebep olup veri kaybına sebep olabilir. Ortalama filtre kullanıldığında gürültü azaltılırken kenar piksellerde bulanıklaşma sebebiyle veri kaybı yaşanabilmektedir. Bu sebeple filtreleme işlemleri yapılırken seçilen yöntem dikkat edilmelidir [55]. Kenar belirleme, görüntülerdeki nesnelerin sınırlarını bulmaya yarayan görüntü işleme tekniğidir. Bu yöntem ile nesne sınırları belirlenir. Bir görüntüde en belirgin kısımlar kenar ve çizgiler olduğundan kenarlar, görüntü için temel özelliklerdendir. Bir görüntünün yoğunluğunda değişiklikler yaparak kenarlar belirlenmiş olur [56]. Kenar belirleme işlemlerinden sonra görüntü, yüksek seviye işlemler olan sınıflandırma ve analiz aşamasına geçilebilir [36]. Kenar belirleme, görüntüde odaklanan önemli verileri belirleyip gürültüyü filtrelediğinden yüz görüntülerinin belirlenmesinde de sıkça kullanılır. Kenar belirleme işlemlerinde de diğer tekniklerde olduğu gibi farklı yöntemler uygulanmaktadır. Bunlardan birkaçından bahsedecek olursak kenar tespiti için kullanılan yöntemlerden biri olan Sobel Kenar Algılama yönteminde 3x3 matris kullanılmaktadır. Kullanılan algorithmada görüntü yoğunluğunun gradyanı hesaplanıp aydınlıktan karanlığa yön verilir. Karanlık ve aydınlık farkları ile yoğunluk belirlenir. Sobel algoritmaları sayıların türevlerini analiz ederek çalışan evrişim adı verilen matematiksel bir prosedür olup 3x3 dizilerde kenar tespiti için bu yöntem kullanılır [57].

-1	-2	-1
0	0	0
1	2	1

x

-1	0	1
-2	0	2
-1	0	1

y

Yatay ve dikey maskelerle kenarlara yatay ve dikey olacak şekilde hesaplanır. En sık kullanılan görüntü işleme araçlarından biri olan Canny Kenar Algılama ile kenarlar çok güçlü bir şekilde tespit edilir. Canny yöntemi birçok alanda kullanılmakla beraber endüstri sektöründe yaygın olarak tercih edilmektedir [57].

Canny yöntemi sırasıyla birkaç adımda gerçekleşir. İlk olarak görüntü iki boyutlu Gauss maskesi ile bulanıklaştırılıp düzeltilir. Böylece kenar özelliği taşımayan piksellerle kenar özelliği

taşıyan pikseller ayrılmış olur. Ardından görüntünün gradyanı alınınca x ve y yönündeki gradyan ile kenarların oluşumunu gösteren yoğunluktaki değişiklikler gösterilmiş olmaktadır. Gradyanın maksimum olduğu noktalar belirlenir. Ancak tüm pikseller için kontrol gerçekleştirilmeden bulunan maksimum değerler hemen bastırılmaz. Her piksel için bir piksel uzaklıktaki pozitif ve negatif yönde olanlar için büyüklüğü kontrol edilir. Eğer piksel ikisinden de büyük değilse onu bastırırız [57]. Canny kenar algılama tarafından kullanılan eşikleme yöntemi de hem yüksek hem düşük eşikten faydalanıldığından, bir pikselin yüksek eşiğin üstünde olması bu pikselin kenar pikseli olarak ayarlanabileceğini gösterir. Eğer piksel düşük eşiğin üzerindeyse ve kenar piksele komşuysa da kenar pikseli olarak ayarlanabilir. Ancak kenar piksele komşu değilse kenar piksel olarak ayarlanamadığı gibi düşük pikselin altındaysa hiçbir şekilde kenar pikseli olamaz [57]. Laplace operatörü tanım olarak iki gradyan vektörün iç çarpımı olarak ifade edilir. Bu operatör skalar bir operatördür [40]. Laplace operatörü görüntülerdeki kenarları bulmak için kullanılan yöntemlerden biridir. Laplace yöntemi ikinci derece türev maskesi iken diğer yöntemlerde birinci derece türev maskesi kullanılmaktadır. Ayrıca Laplace, herhangi bir yönde kenar çıkarması yapmaz. Laplace operatörünü pozitif ve negatif laplace olmak üzere ikiye ayırabiliriz [59].

0	-2	0
-2	0	-2
0	-2	0

Negatif Laplace

1	1	1
1	-8	1
1	1	1

Pozitif Laplace

Görüntü analizi yaparken öncelikle dikkat etmemiz gereken hususlardan biri de görüntü bölütleme ve ayrıştırma işlemleridir. Görüntü bölütleme, bir görüntünün birbiriyle örtüşmeyen anlamlı parçalara bölünmesiyle oluşturulur. Ayrıştırma yapıldıktan sonra oluşturulan anlamlı parçalara etiketleme işlemi yapılır [60].

Görüntü ayrıştırmada genel bir yöntem olmadığından probleme uygun olarak görüntü ayrıştırma algoritmaları uygulanmaktadır. Diğer tekniklerde olduğu gibi görüntü ayrıştırma işlemlerinde de görüntüde bulunan gürültüler bu işlemi zorlaştırmaktadır. Bu sebeple görüntüde ayrıştırma yaparken gürültülü alanlarla gürültülü olmayan alanların ayrı ayrı ayrıştırma işlemi gerçekleştirmek tercih edilmektedir [60].

Bölütleme tekniklerinin genel bir yöntemi bulunmadığından kullanılan teknikleri maddeleyecek olursak bunlar; piksel tabanlı teknikler, bölge tabanlı teknikler, grafik tabanlı teknikler, yapay sinir ağı tabanlı teknikler, sınır tabanlı teknikler, model tabanlı teknikler ve melez

teknikler olarak sıralanabilir. Bu teknikler probleme uygun olarak görüntüde seçilip kullanılır [61].

Görüntü işleme tekniklerinden biri olan görüntü onarma, bozulmuş olan bozuk görüntü üzerinde görüntüyü iyileştirmek amacıyla kullanılan bir tekniktir. Bu teknik sayesinde bozuk olan görüntü gürültülerden temizlenmiş olur. Bu işlemi yapabilmek için öncelikle görüntüdeki gürültü türü belirlenir. Görüntü onarımını; mekânsal alan teknikleri ve frekans alanı teknikleri olmak üzere ikiye ayırabiliriz. Mekânsal alan tekniklerinde piksel değerleri ile işlemler yapıp görüntü iyileştirilir. $f(x,y)$ orijinal görüntü olmak üzere $n(x,y)$ gürültüyü temsil ederse bu gürültü ile oluşan görüntü $g(x,y)$ olsun. $f(x,y)$ görüntüsünün tümleyeni elde edilerek onarım süreci yapılır.* sembolü konvilüsyonu temsil etmek üzere $h(x,y)$ ise bozulmaya (distorsiyon) neden olan fonksiyondur [62].

$$g(x,y) = h(x,y) * f(x,y) + n(x,y) \quad (1.3)$$

Frekans alanı yönteminde ise frekans alanına aktarılan görüntüde Fourier Dönüşümü hesaplanıp tüm iyileştirme yöntemleri gerçekleştirilir. Ardından ise son ters Fourier Dönüşümü ile en son görüntü elde edilmektedir [62].

Dijital görüntü işleme tekniklerinden biri olan görüntü eşlemede, farklı görüntülerde bulunup aynı bilgileri içeren alanlar eşleştirilip yapılması gereken dönüşümler sağlanarak görüntü eşleştirme işlemi gerçekleştirilmiş olur. Analog olarak alınan görüntülerin sayısala dönüştürülüp işlenebilmesi için yapılan ön hazırlık işlemlerinden biri de görüntü eşleme işlemidir [63]. Görüntü eşleştirme yapılırken minimum iki görüntü alınıp biri referans görüntüsü olarak belirlenir. Bu görüntü diğer görüntüler ile aynı koordinat sistemine getirilmelidir. Bunun için gerekli dönüşümler yapılır. Görüntü eşleme yapılırken kontrol noktaları seçilir. Bu kontrol noktaları aynı noktaları temsil eder. Seçilen bu noktalar görüntü eşleştirmede oldukça önemlidir ve başarıyı etkilemektedir [63].

Görüntüler içerisinde birçok bilgi bulunmaktadır. Bu bilgilerden bir kısmı görüntü işleme yapıldığında ihtiyaç duyduğumuz verileri temsil ederken bir kısmı da ihtiyacımız olmayan gereksiz verileri temsil etmektedir. Görüntü işleme tekniklerinden olan görüntü sıkıştırma yöntemi veri sıkıştırma temeline dayanmakta olup amacı fazlalığı azaltmaktır. Görüntü sıkıştırma teknikleri ile görüntülerdeki bilgileri daha verimli şekilde kullanıp saklayabilir ve daha kolay bir şekilde bu verileri iletebiliriz [64].

Pikseller görüntünün kalitesini belirlemekte oldukça önemlidir. Sıkıştırma işlemleri yaparken pikseller azalacak ve görüntü kalitesi de bu oranda azalmış olacaktır. Görüntülerin orijinal formatı BMP iken görüntü farklı formatta saklanacaksa seçilen formata göre veri kayıpları

oluşmaktadır. Örneğin en az kayıp oranı PNG formatında bir sıkıştırma yapılırsa gerçekleşmektedir [65].

Son yıllarda gelişen teknolojiyle mevcutta kullanılan sistemler güçlenerek gelişmiştir. Özellikle yapay zekâ tabanlı uygulamalar ile gelişim son hız devam etmektedir. Yapay zekâ kullanılarak geliştirilen sistemlerde daha hızlı ve daha kesin tespitler yapılmaktadır. Derin öğrenme algoritmaları ve görüntü işleme teknolojilerinin birlikte kullanılmasıyla çözümü çok zor olan problemler kolayca çözülebilmektedir [66].

Görüntü işleme ile görüntü üzerinde yapılan işlemlerle sayısallaştırılan görüntüden yararlı bilgiler çıkarılır. Nesne tanıma ve izleme ile birçok zorluk giderilmektedir. Bunlara örnek verecek olursak video görüntülerinden izleme yapılarak güvenlik sağlamaları, trafik yönetimi gibi birçok alanda kullanımı bulunmaktadır.

Görüntü işleme tekniklerinin gelişmesiyle artan başarılı doğruluk oranları sonucunda bu alanda yapılan çalışmalar birçok sektörde uygulanmaya başlanmıştır. Görüntü işleme teknikleri kullanılarak gerçekleştirilen nesne tanıma sayesinde özellikle endüstri sektöründe kullanımları artmıştır [67].

Nesne tespiti yaparken ilk olarak veri girişi ve ön işleme aşamaları gerçekleştirilmelidir. Veriyi işleme uygun hale getirilmek için ön işleme yöntemleri uygulanır. Veri gürültülerden temizlenip istenilen formatta girdi olarak sisteme verilir. Veri ön işleme yöntem ve algoritmalarından uygun olanları seçilip uygulanır. Bir cismin önceden tanımlanmış özellikleri mevcuttur. Bu özellikler sayesinde öznitelikler çıkarılır. Bu görüntünün ne olduğuna özniteliklerle karar verilmesiyle tanımlama yapılır. Bir nesnenin tespitinde renk, şekil gibi görsel öznitelikler ve hareket bilgileri kullanılmaktadır. Hangi özniteliklerin kullanılacağı durumdan duruma göre farklılık göstermektedir. Bu aşamadan sonra kümeleme ve sınıflandırma işlemleri yapılmaktadır. Öznitelikleri çıkarılan verimizi benzer verilerin olduğu daha önceden belirlenmiş bir sınıfa dâhil ederek sınıflandırma, benzer özelliklere sahip verilerle aynı grup altında toplayarak da kümeleme yapılmış olunur [66].

Aşağıda nesne tanıma ve izleme ile ilgili bulunan görselde temel adımlar bulunmaktadır.




Şekil 1.11. Nesne Tanıma ve İzleme Adımları

Tüm bu işlemler ilk olarak videodan görüntünün alınmasıyla başlamaktadır. Nesneler video karesinde belirlenip tanımlanır. Ardından pikseller kümelenir. Sınıflandırma işlemi yapılırken nesneler ayrı ayrı kendine has özniteliklerine göre sınıflandırılır. İlgi bölgesi (ROI) seçiminden sonra video içerisindeki hareketleri ve bulundukları konumların izlenmesiyle nesne izlenmesi gerçekleştirilmiş olur. Videoda nesne ilk görüldüğü anda analiz etme süreci başlar. Arka plan nesneleri ortadan kaldırılır ve takip edeceğimiz nesneye odaklanılır [68].

Nesne algılama ve izleme yöntemlerinin birbirlerine göre avantaj ve dezavantajları bulunmaktadır. Arka plan çıkarma yönteminin çerçeve farkı ve optik akış algılama yöntemi ile karşılaştırıldığında nesne hakkında bilgi veren en kolay yöntem olduğu belirlenmiştir. Çekirdek ve kontur tabanlı izlemede nesne sadece ekranda ilk görüldüğünde algılama gerektirirken nokta izlemede her karede algılama gerçekleştirmektedir [68]. Yapılacak çalışmalarda nesne izlemelerinde oluşacak izleme hatalarını minimum seviyeye indirmek için seçilen yöntem ve kullanılacak algoritmanın en uygun şekilde seçilmesi oldukça önemlidir.

1.2.6. Duygu Analizi

İnsanlar arası iletişimde büyük öneme sahip olan yüz ifadeleri teknolojinin gelişmesiyle elektronik ortamlarda da öğrenilip analiz edilmesi istenen bir konu olmuştur. İnsan yüzü kamera veya benzeri donanımla alınarak belirlendikten sonra analizleri yapılarak sahip olduğu duyguya göre sınıflandırılması yapılmaktadır. İnsanlar arası etkileşimde kolayca yapılan bu analiz insan bilgisayar arası etkileşimde oldukça zordur. Bilgisayarın insanları taklit edip bu öğrenme ve analiz etme aşamalarını gerçekleştirebilmek için teknikler geliştirilmiştir. Bu işlemlerin makinelerde doğru ve hızlı şekilde yapılmasını sağlamak amacıyla geliştirilen algoritma ve teknikler mevcuttur. Duygu analizi için aşağıdaki sınıflandırma teknikleri kullanılır.



Şekil 1.12. Duygu Sınıflandırma Teknikleri [82]

İnsan yüzünde bulunan bölümlerin (ağız, burun, çene, göz, kaşlar gibi) kaslarında oluşan şekilsel değişiklikler ile yüz ifadeleri belirlenmektedir. Bu şekilsel değişikliklerle işlemler yapıp sınıflandırma yapılmaktadır. Yüz ifade sınıfları;

Mutluluk, şaşkınlık, iğrenme, öfke, doğal, korkma, üzüntü olmak üzere yedi duygu sınıflandırması yapılabilir.

2. MATERYAL VE YÖNTEM

Bilimsel hesaplamalarda en çok kullanılan dillerden biri olan python, gelişmiş kütüphaneleri ile algoritmik gelişmelerde ve veri analizi işlemlerinde oldukça popüler olan bir dildir. Akademik ortamlarda kullanıldığı gibi endüstride de kullanımı yaygındır [69].

Dinamik yazım ve bağlamıyla birleştirilmiş, nesne yönelimli, yorumlanmış bir dil olan Python üst düzey bir programlama dilidir. Mevcut bileşenleri birbirine bağlamada komut dosyası veya yapılandırılmış dili olarak kullanılması ile hızlı uygulama geliştirme özelliği pythonu daha çok ilgi çekici bir dil haline getirmiştir. Kullanılması ve öğrenmesi kolay bir dildir. Ayrıca derleme adımı olmadığından düzenleme-test-hata ayıklama döngüsü oldukça hızlıdır. Programda bir hata meydana geldiğinde yorumlayıcı istisna oluşturur. Eğer program hatayı yakalayamazsa yorumlayıcı izleme yazdırması sağlar. Böylece bölümlene hatası oluşmamış olur. Bu sebeple düzenleme-test-hata döngüsü hızlıca gerçekleştirilir [70].

Veri bilimi ve makine öğrenimi alanında yaygın olarak kullanılan python büyük verileri işlemek ve matematiksel hesaplar da yaparak makine öğrenimini de gerçekleştiren en popüler dil halindedir. Ayrıca web ve mobil uygulamaların dışında her türlü programlama ve yazılım geliştirmek için kullanılırken bir bilgisayar sistemi için sistem komut dosyaları yazmak için de kullanılmaktadır. Python kolay öğrenimi ve yazımı olmasına rağmen en karmaşık problemlerde tercih edilir. Pythonu diğer dillerden ayıran en önemli özelliği; diğer dillerden çok daha fazla genişletilebilir olan kendi işlevleri ile uygulamalar yazabilmesidir [71].

Bilimsel hesaplamalar için kullanılan Numpy, matematiksel, mantıksal işlemlerde sıralama işlemlerinde ve diziler üzerinde yapılan işlemlerde hızlı işlem yapabilmek için kullanılan bir python kitaplığıdır. Yaptığı bilimsel işlemlere örnek olarak fourier dönüşümleri, doğrusal cebir işlemleri, temel istatistiksel işlemler verilebilir. Numpy ile ileri düzey matematiksel işlemler yapılırken diziler üzerindeki işlemler daha verimli olarak ve daha az kodla işlemleri gerçekleştirir. Bilimsel ve matematiksel işlemleri gerçekleştirirken python dizisi girdisi desteklense de verimi artırmak amacıyla numpy dizilerine dönüştürme işlemleri gerçekleştirilir [72].

Büyük verileri işleme, işlemleri hızlı yapabilme özelliklerinden ve söz dizimleri ile yüksek performanslı matris hesaplama yetenekleri sebebiyle makine öğrenmesinde sıklıkla tercih edilen popüler bir kitaplıktır [73].

Açık kaynak kodlu python diliyle yazılan pandas da yüksek performans, hız ve kullanım kolaylığı sağlar. Python dışında C, Cython dilleriyle de yazılmaktadır [32].

Python'da yüksek performansla veri işleme, analiz etme işlemleri için kullanılan açık kaynaklı bir kitaplık olan Pandas, Numpy paketi üzerine inşa edilmiştir. Pandas'ın çalışması için

Numpy gereklidir. Python veri işleme özelliğine sahiptir. Ancak sınırlı destek sağlar. Bu sebeple Pandas geliştirilmiştir. Pandas'ta veri kaynağına bakılmaksızın veri işleme ve analizi gerçekleştirilir [73]. Pandas modülü ile NumPy modülleri arasındaki bazı farklardan bahsedecek olursak;

Tablolar üzerinde işlem yapmamız isteniyorsa Pandas, sayısal veriler üzerinde işlem yapmamız gerekiyorsa Numpy tercih edilir. Pandaların aracı veri çerçevesi ve serilerken; NumPy'nin aracı dizilerdir. NumPy, Pandaya göre bellek açısından daha verimlidir. Pandas belleği daha fazla tüketir. Satır sayılarına göre karşılaştırma yapıldığında, Pandas 500K ve üzerindeyse performansı iyi iken, NumPy'da satır sayısı 50K ve altında olduğunda performans iyidir. Dizilerin indekslenmesi konusunda NumPy'a göre çok yavaştır. Pandas 2D tablo nesnesi sunarken Numpy çok boyutlu diziler sunar [73].

2.1. OpenCV ve Bileşenleri

Görüntü işleme teknolojileri ile yapılan uygulamaların artmasıyla görüntüyü işlemek amacıyla birçok farklı araç ve kütüphane geliştirilip kullanılmaktadır. Bu çalışmada görüntü işleme kütüphanelerinden OpenCV kütüphanesi kullanılmıştır.

Intel tarafından geliştirilen ve C dili ile yazılmış olan OpenCV genellikle bilgisayarlı görme ve görüntü işleme alanlarında kullanılan açık kaynak kodlu bir kütüphanedir. Sabit bir image veya video üzerinde görüntüleri işleme özellikleriyle kullanım alanı oldukça geniştir. Değişen işlemci donanım teknolojileriyle uyumluluk gösteren OpenCV hesaplama verimliliği ve eş zamanlı uygulamalarda güçlü odaklanma için tasarlanmış olup, hız bakımından optimize edilmiş fonksiyonlardan oluşmaktadır. OpenCV platform bağımsız olduğundan birçok programlama diliyle geliştirilebilir. Uygulamalarda daha fazla performans elde etmek için Intel tarafından IPP (Intel Performance Primitives) geliştirilmiş olup IPP ile OpenCV'nin işlem çözme özelliği artırılmış olur [36].

Gelişen teknolojiyle beraber görüntü işleme alanındaki uygulamalar artmış ve kullanılan kütüphaneler ve araçlarla da görüntü işleme kolaylaşmıştır. OpenCV kullanılarak yapılan uygulamalara örnek verecek olursak; yüz tanıma, plaka sistemi tanıma, nesne tanıma ve izleme, tıp ve endüstride kullanılmak üzere geliştirilen görüntü işleme uygulamaları, astronomi ve uzay bilimlerinde uydu ve gezegen görüntüleri işleme verilebilir.

OpenCV kütüphanesinin fonksiyonlarını CV, MLL, HighGUI, CXCORE ve CXAux olmak üzere beş ana kütüphanede tanımlayabiliriz. CV, görüntüler üzerinde işleme yaparken kullanılan en temel kütüphanedir. MLL, CV ile işlenmiş görüntüden çıkarım yapmayı sağlar.

İstatiksel sınıflandırma ve kümeleme işlemleri burada sağlanır. HighGUI, görüntü yükleme ve kaydetme fonksiyonları video giriş çıkış fonksiyonlarını tanımlar. CXCore bileşeni ise veri yapılarının tanımlandığı ve xml desteğinin sağlandığı kütüphanedir. Ağaçlar, hata işleme fonksiyonları burada tanımlanır. CXAux bileşeni ile de şekil eşleştirme yapılır. Örnek verecek olursak; yüz tanıma, hareket tanıma, 3D takip fonksiyonları gibi pek çok deneysel algoritma bu kütüphanede tanımlanır [36].

Intel tarafından geliştirilip bilgisayar görüşü uygulamalarında sıklıkla kullanılan OpenCV'nin uygulama alanlarına birçok örnek verilebilir. Bunlardan bazıları; yüz tanıma sistemleri, hareket tanıma ve takibi, nesne tanıma, artırılmış gerçekliktir. Örnekler gün geçtikçe daha da artmaktadır [50].

CV bileşeni, sabit veya hareketli görüntü üzerinde yüksek seviyede görüntü işleme algoritmaları sunan bu kütüphane OpenCV'nin en temel bileşenidir. Görüntünün yapısal analizini sağladığı gibi hareket analizini sağlayarak nesne takibini de gerçekleştirmiş olur. Kenar belirleme, köşe bulma, filtreleme, renk dönüşümleri, histogramlar, hesaplamalı geometri (CvBoc2D, CvQuadEdge2d gibi) bu bileşenle bulunup belirlenmektedir. Görüntü tanıma özelliği ile nesne algılamaları gerçekleştirmektedir. CvHaarClassifier, CvHaarClassifierCascade gibi fonksiyonlar CV kütüphanesinin sağladığı fonksiyonların sadece bir kaçıdır [36]. MLL bileşeni, işlenen görüntüden çıkarımlar yapılmasını sağlayan kütüphanedir. Verileri sınıflandırmak veya kümeleme işlemlerini gerçekleştirmek için veri yapılarını sunar. Karar verme ağaçları, rastgele ağaçlar, yapay sinir ağları, K'nın en yakın komşuları modeli MLL kütüphanesinin sağladığı fonksiyonlardan sadece bir kaçıdır [36].

2.2. Haar Cascade

Dijital ortamda bulunan sabit veya hareketli görüntüde işleme yapabilmek için öncelikle insana ait yüzün belirlenmesi gerekmektedir. Yüz tespiti işlemlerinde genel olarak iki yöntem bulunmaktadır. Bunlar; yüzün bir bütün olarak ele alındığı “Bütünsel Yaklaşım” ve sadece ön yüze ait yüz elemanlarını inceleyerek tanıma yapmaya olanak sağlayan “Analitik Yaklaşım” dır. Bütünsel yaklaşıma örnek olarak Nokta Dağılım Modeli (PDM) ile yüzü ön ve yan profilden işleme verilebilir. Analitik yaklaşıma örnek ise iris lokalizasyonu yöntemi verilebilir [74].

Viola ve Jones [75] yüz tanıma yöntemlerine farklı bir bakış kazandırmış olup geliştirdikleri algoritma ile herhangi bir sensör kullanmadan yüz tespitinin gerçek zamanlı olarak yapılmasını sağlamışlardır. Bu algoritma sayesinde 15 fps (frame per second) hızında yüz tespiti gerçekleştirilmiş olup algoritmanın çalışma hızı artırılabilir.


En yüksek hız ve en büyük doğruluk oranı cascade sınıflandırıcısı ile yüz işaretçileri hizalama tekniğinin birlikte kullanılmasıyla gerçekleştirilen çalışmada elde edilmiş olup; en başarılı yüz tespit algoritması Chen ve arkadaşları [76] bu yöntemleri kullanılarak gerçekleştirilmiştir [74].

En yüksek doğruluk oranını verdiğiinden yapılan çalışmada insan yüzlerini algılamak için Haar-Cascade sınıflandırıcı algoritması tercih edilmiş ve kullanılmıştır. Sabit veya hareketli bir görüntüdeki nesneleri veya insan yüzlerini tespit etmek amacıyla kullanılan Haar Cascade sınıflandırıcı algoritmasında verimliliği artırmak için ilk olarak integral görüntü üretilmektedir [74].

İnsan yüzü algılamada kullanılan haar özellikleri haar sınıflandırıcısının ana parçası olup, haar öznitelikleri görüntüdeki öznitelikleri tespit etmek amacıyla kullanılmaktadır. Her özellik beyaz dikdörtgenin altındaki piksel sayısının siyah dikdörtgenin altındaki piksel sayısından çıkarılmasıyla hesaplanarak üretilen tek bir değerden oluşmaktadır [77].

Haar özellikleri bir pikselin yoğunluk değerini kullanmak yerine bitişik dikdörtgen piksel grupları arasındaki kontrast değerlerini kullanarak göreceli açık ve koyu alanları belirler. Bu varyanslar ile iki veya üç bitişik grup haar benzeri bir özellik oluşturur [78].

Aşağıdaki görselde de kenar özellikleri, çizgi özellikleri ve merkez çevre özelliklerini belirten haar benzeri öznitelikler gösterilmiştir.



Şekil 2.1. Haar-Benzeri Öznitelikler [78]

Haar özellik taraması görüntü üzerindeki sol üst köşeden başlayıp sağ alt köşeye kadar yapılır. İnsan yüzlerini algılayabilmek için bu tarama birkaç kere yapılmaktadır. Verimliliği ve

hızı artırmak için integral imaj üretilmektedir. İntegral görüntüde dikdörtgendeki köşelerin piksel sayılarının (x, y) değeri hesaplanmalıdır [77].

Eğer $A[x, y]$ orijinal görüntü ise, $AI[x, y]$ integral görüntüdür ve integral görüntü bir pikselin solunda ve (x, y) dahil konumdaki pikselin üstünde bulunan piksellerin yoğunluk değerlerinin toplamını içeren bir dizidir. İntegral görüntü aşağıdaki denklemde olduğu gibi hesaplanmaktadır [78].

$$AI[x, y] = \sum_{x' \leq x, y' \leq y} A(x', y') \quad (1.4)$$

Döndürülmüş integral görüntü ise 45 derece döndürülerek elde edilen görüntüdür. x değeri için sola ve yukarıya 45 derecelik açıyla ve y değeri için aşağısında bulunan piksellerin yoğunluk değerinin toplamı bulunarak hesaplanır. $A[x, y]$ orijinal görüntü ise $AR[x, y]$ döndürülmüş integral görüntüdür. Döndürülmüş integral görüntü ise aşağıdaki denklemle hesaplanmaktadır [78].

$$AR[x, y] = \sum_{x' \leq x, x' \leq x - |y - y'|} A(x', y') \quad (1.5)$$

Yüz tespiti işlemlerini gerçekleştirebilmek için algoritmanın eğitilmesi gerekmektedir. Bu eğitim için veri kümesine ihtiyaç vardır. Kullanılacak veri kümesi içerisinde görüntüde aradığımız verinin olduğu pozitif görseller ve aradığımız verilerin bulunmadığı negatif görseller olmalıdır. 24x24 piksel boyutundaki alt görüntülerle tüm resimde kaydırma işlemi yapılarak aranan nesne taraması yapılır [74]. Bu özelliğin hesaplanması oldukça verimli ve hızlı olsa da 24x24 alt görüntünün içerdiği görüntülerin tümünün hesaplanması zaman alıcıdır. Ancak tüm görüntülerin hesaplanmasına gerek yoktur. Bir alt görüntünün istenen veriyi içerip içermediğini belirlemek için özelliklerin bir kısmı yeterlidir. Alt görüntüler analiz edilirken bir nesneyi tanımlayan özelliklerden birkaçı kullanılır. Böylece aranan nesneyi içermeyen alt görüntüler mümkün olduğunca ortadan kaldırılmaya çalışılır [78]. Görüntü içerisinde bulunan alt görüntülerde pozitif ve negatif bölgelerin tespitinin zaman alıcı olması sebebiyle Viola ve Jones tarafından AdaBoost algoritmaları kullanılmış ve böylece son derece hızlı bir şekilde haar özellikleri seçilip bu özelliklerin eğitilmesi sağlanmıştır [74].

Bir nesneyi ayıran tüm haar özelliklerinde sadece en yüksek olasılığa sahip alt görüntülerin analiz edilmesi sağlanarak sınıflandırıcılar basamaklandırılmalıdır. Aşama sayısı azaltılarak pozitif oran artırılabilir [78]. Viola ve Jones 200 basit özellikle insan yüzü algılamasında %95 doğruluk oranını yakalamışlardır [79].

Ağız, gözler ve burun gibi insan yüz özelliklerinin tespit edilebilmesi için haar sınıflandırıcı basamakları eğitilmeli ve AdaBoost algoritması uygulanmalıdır. Intel'in geliştirdiği OpenCV ile programların uygulanması kolaylaşmıştır. OpenCV, haar sınıflandırıcı tespiti ve eğitiminin uygulamalarını içermektedir. Eğitim için ihtiyaç olan iki dizi görüntüye ihtiyaç vardır. Biri negatif görüntüleri içermeli diğeri ise pozitif görüntüleri içermelidir. Doğruluk oranı en yüksek yüz özelliklerinin algılanabilmesi için ırk, cinsiyet, yaş farklılıkları olan insan görüntülerinden veriler olmalıdır [78].

2.3. Dlib

C++ programlama dilinde geliştirilmiş günümüzde de geliştirilmeye devam eden dlib kütüphanesi; makine öğrenmesi, derin öğrenme, bilgisayarlı görü işlemlerini içeren günlük hayatta problemleri çözmek için kullanılan ileri seviye bir kütüphane olup platform bağımsızdır. C++ ile geliştirilmiş bir araç olsa da python veya java ile geliştirilmek istendiğinde de kullanılabilir. Dlib kütüphanesi sayesinde yüz tanıma ve izleme gibi işlem ve uygulamalar yapılabilmektedir [80].

İnsan yüz hatları ve ağız, burun, göz gibi yüzde bulunan kısımları yerlerini belirten 68 nokta bulunmaktadır. Bunlara işaretçi de denilmektedir. İşaretçilerin her biri x ve y koordinatında bir noktayı temsil etmektedir. Nokta0(x0,y0).....Nokta67(x67,y67) olmak üzere 68 noktayı belirtir. Bu işaretçilere ait koorninat bilgileri tespit edilip takip edildiğinde yüz işaretçilerindeki değişimler öznelitliklerin değişmesiyle duygusal durum farklılıklarını da belirlemeye olanak sağlamış olmaktadır [74].



Şekil 2.2. Noktalar Haritası [81]

Çene, sol kaş, sağ kaş, burun, sağ göz, sol göz, ağız ve dudak noktalarının koordinat

değerleri değıştikçe bunların birbiri arasındaki öklid uzaklıkları hesaplanarak elde edilen uzaklıklar sayesinde öznitelikler çıkarılır. Bu öznitelikler ile kişinin duygusal durumu belirlenmiş olmaktadır [74].


Scikit-learn; orta ölçekli denetimli ve denetimsiz problemler için çok çeşitli son teknoloji makine öğrenimi algoritmaları entegre eden bir python modülü olmakla beraber, yüksek seviye bir dil kullanarak makine öğrenimine odaklanmıştır. Kullanım kolaylığı, performans, dökümantasyon ve API tutarlılığı en büyük avantajlarındandır. Scikit-learn; python diliyle entegre halde bulunup kullanımı kolay olan bir arayüz sağlarken pek çok makine öğrenimi algoritması bu zengin modülü kullanarak son teknoloji uygulamalarını geliştirebilirler. Sadece bilgisayar biliminde değil biyoloji, fizik gibi birçok alanda da istatistiksel veri analizi ihtiyaçlarına da cevap vermektedir [69].

Scikit-learn pythonda yazılmış olup giderek kullanımı artmış bir makine öğrenimi kitaplığıdır. Uzman ve uzman olmayanlar için basit ve ayrıntılı tasarlanmış olup oldukça faydalı ve çeşitli bağlamlarda yeniden kullanılabilir şekildedir. BSD lisansı ile dağıtılır ve kullanımı ücretsizdir. 2007 yılında geliştirmesi başlamış olup çeşitli uzmanlardan oluşan uluslararası bir ekip ile geliştirilmiştir. İçinde bulunan tüm algoritmalar iyi tanımlanmış bir dizi yöntemden oluşan basit bir API ile düzenlenirken, bu API sayesinde kullanışlı hale gelmektedir. Bu kütüphane çok boyutlu dizilerin verimli depolanması ve manipölasyonu için NumPy'ı kullanır. Numpy ile makine öğrenimi algoritmaları ve veri analizi sorunsuz olarak çalışıp kapsamlı bir bilimsel çalışma ortamı sunmaktadır [83].

Açık kaynaklı bir makine öğrenimi kitaplığı olan scikit-learn; model uydurma, veri ön işleme, model seçimi ve diğer birçok yardımcı program için çeşitli araçlar sağlamaktadır. Bu özellikleri sayesinde kullanımı hızla artmaktadır [84].

Scikit-learn'de hızlı bir şekilde hesaplamalar yapabilmek için eğitim ve test kümeleri oluşturulmaktadır. Bir tahmin fonksiyonun parametrelerini öğrenmek ve onu aynı veriler üzerinde test etmek hatalıdır. Çünkü bir model kısa süre önce gördüğü örneklerin etiketlerini tekrarlırsa yüksek bir puana sahip olacak fakat henüz görmediği veriler için yararlı bilgileri tahmin edemeyecektir. Bu sebeple bu yöntem metodolojik bir hataya sebep olmaktadır. Hataya sebep olan bu duruma “aşırı uyum” adı verilmektedir. Bu durumdan kaçınmak için yaygın olarak kullanılan yöntemlerden biri; mevcut verilerin bir kısmını `x_test` ve `y_test` olarak veri kümesi halinde tutmaktır. Makine öğreniminde deney kelimesi sadece akademik alanda kullanılmamakta olup ticari ortamlarda da çalışmalar çoğunlukla deneysel olarak başlamaktadır. Scikit-learn'de rastgele bölünmüş eğitim test verileri `train_test_split` yardımcı fonksiyonu ile hızlı ve kolay bir şekilde hesaplanıp bulunabilmektedir. Test kümesinin yanında veri kümesinin bir kısmı da doğrulama kümesi olarak adlandırılır. Eğitim; eğitim kümesinde devam ederken doğrulama kümesi ile de

değerlendirmeler yapılır, çalışma başarılı bulunduğunda test kümesi üzerinde son işlemler ve değerlendirmeler yapılır [85].



Şekil 2.3. Tipik Çapraz Doğrulama İş Akışının Akış Şeması

2.4. Makine Öğrenmesi


Yapay zekâ ile başlayan teknolojiadaki gelişmeleri, derin öğrenme ve makine öğrenmesi alanındaki gelişmeler takip etmiştir. Makine öğrenmesi de günümüzde kullanım alanı oldukça fazla olan ve gün geçtikçe de artmaya devam eden bir alan olmaktadır. Makine öğrenmesi algoritmaları sayesinde herhangi bir veri kümesi referans alınarak yeni girdinin tahmin edilebilmesi sağlanabilmektedir. Bir komut işlenip çıktısı belirlenirken bu işlemin nasıl yapılacağını öğrenmesi için büyük miktarda veri ve buna uygun algoritmalara ihtiyaç duyar. Bu veri ve algoritmalar kullanılarak eğitim gerçekleştirilir [82].

Makine öğrenimi bir yapay zekâ dalıdır. Makine öğreniminde veri çok önemlidir. Verilerden öğrenme gerçekleştirilir. Zamanla doğruluk oranını artırmaya odaklanılmıştır. Makine öğreniminde geliştirilen algoritmalar verilerden, kararlar ve tahminler çıkarır. Bunun için yüksek miktardaki verilerde bulunan özellikleri bulmak amacıyla eğitim gerçekleştirilir. İstatiksel işlem adımlarına algoritma denilmektedir. Kullanılan algoritmanın güçlü olması ve işlenen verinin sayıca fazla olması tahmin sonucunu olumlu etkilemektedir [86].

Makine öğreniminin çalışma mantığını özetleyecek olursak; eğitim veri kümesi oluşturulur ve bu veriler etiketlenir. Etiketleme sadece eğitim verilerinde gerçekleştirilmiş olup diğer verilerde

uygulanmamalıdır. Eğitim veri kümesi belirlenip etiketlemeler yapıldıktan sonra bu verilerin türüne ve probleme uygun algoritma seçilmelidir. Algoritma seçildikten sonra bu algoritmayı eğitmek gerekmektedir ve bu yinelemeli bir süreçtir. Değişkenler çalıştırılıp çıktı üretilir ve ardından sonuçlarla karşılaştırılır . Sonuçta oluşan eğitilmiş algoritma, makine öğrenimi modeli olmaktadır. Bu adımdan sonra ise son aşamada elde edilen makine öğrenimi modelini yeni verilerle kullanıp doğruluğu artırmak amaçlanır [86].

Makine öğrenmesini temel olarak gözetimli (supervised) öğrenme, gözetimsiz (unsupervised) öğrenme ve yarı gözetimli (semi-supervised) öğrenme olmak üzere üç ana başlığa ayırabiliriz.



Şekil 2.4. Makine Öğrenmesi Sınıfları

2.4.1. Gözetimli Öğrenme

Genelleştirdiğimiz bir işlevi eğitmek amacıyla etiketli eğitim verileri kullanılarak sonradan gelecek yeni örnek verilerin eğitilmesi işlemine gözetimli öğrenme denilmektedir. Gözetimli öğrenmede giriş verileri ve istenen çıktıdan oluşan etiketli eğitim verileri kullanılır. Etiketli veriler öğrenme süreci boyunca kullanılırken çıktı, girdi verisinden tahmin edilmektedir. Etiketli veriler eğitim veri kümesi olarak kullanılmaktadır. Bu veriler ile bir model oluşturulur. Eğitim sonucunda ideal doğru yanıtı veren çıktı oluşturmak amacıyla bu işlev yeni gözlemlere uygulanabilir. Bir model oluşturmak için kullanılan veri kümesi bulunur. Elde edilen modelin doğruluğunu

onaylamak amacıyla yeni veriler kullanılır [86]. Gözetimli öğrenme ile giriş ve çıkış değerleri arasındaki ilişki öğrenilerek yeni bir girdi değeri için çıktı değeri tahmin edilebilir [87].




Şekil 2.5. Gözetimli Öğrenme

2.4.2. Gözetimsiz Öğrenme

Etiketsiz verilerin toplanmasının ek açıklamalı verilerin toplanmasından daha kolay olduğu durumlarda gözetimsiz öğrenme tercih edilmektedir. Denetimsiz öğrenme, etiketlenmemiş veri kümelerinde kullanılmaktadır. Bu yöntemle de giriş verilerinden model benzerliği bulmak hedeflenmektedir [88]. Denetimsiz öğrenme, denetimli öğrenme için ön işleme olarak kullanılabilir [87].

Denetimsiz öğrenme ile verilerdeki gizli özellikler keşfedilerek normal olmayan durumların belirlenmesi gibi işlerde tercih edilir. Veriler bu şekilde gruplanarak ham veriler hakkında bilgi edinilir. Bu yöntem ile veriler etiketsiz olarak gruplandırıldığından sonucu değerlendirmenin bir yolu yoktur. Denetimli öğrenme ile denetimsiz öğrenme arasındaki en temel fark budur [89].



Şekil 2.6. Gözetimsiz Öğrenme

2.5. Yapay Sinir Ağları

Teknolojideki hızlı ilerleme sonucu insana ait özelliklerin makinelere aktarılması üzerine çalışmalar hız kazanmıştır. İnsana ait olan öğrenme özelliği bilgisayarlara aktarılacak istenmiş ve bu konuda çalışmalar yapılmıştır. Makinelere öğrenme yeteneğinin aktarılması kolay bir işlem değildir. İnsan beyninin çalışma mekanizmasına benzer bir yapıya ihtiyaç vardır. Yapay sinir ağları burada devreye girmiştir. Buradan da anlaşıldığı üzere yapay sinir ağları genellikle insanlardaki sinir ağ yapısının modellenmiş bir taklididir.

İnsan beyninin çalışma mekanizması örnek alınarak bu işlemi yerine getirebilecek bir model tasarlanır. Yapay sinir ağlarında sinir hücreleri birbirine farklı şekillerde bağlıdır. Katmanlı bir yapısı bulunmaktadır [90].

Yapay sinir ağları sayesinde insanlarda olduğu gibi örneklerden elde edilen bilgilerle öğrenme, birbiriyle bağlantı kurma, sınıflandırma, özellik çıkarma, optimizasyon gibi işlemler gerçekleştirilebilmekte ve bu çıkarımlar sonucunda kendi deneyimleri ile karar verebilmektedirler [91].

2.5.1. Yapay Sinir Ağları Yapısı


Yapay sinir ağlarında temel amaç insan beyin çalışma mekanizmasını takip edip modellemek olduğundan yapısını açıklarken biyolojik sinir ağlarının yapısını bilmek önemlidir.

Bilgisayar teknolojisindeki hızlı gelişmeler neticesinde işlem hızı nanosaniye seviyesinde olmasına rağmen bu sistemler insan beyninin işlevselliğiyle kıyaslanamayacak kadar küçüktür. Ancak başarıları gün geçtikçe arttığından uygulama alanları da artmaktadır [90].

Biyolojik sinir sisteminde en temel parça nöronlar olup sinir hücreleri; hücre gövdesi (soma), dentrit ve akson olarak üç temel parçada bulunmaktadır. Bir sinir hücresinden sorumlu olan parça somadır. Soma hücrelerin işleyiş ve kontrolünden sorumludur. Dentritler bir nöronda birden çok bulunabilir ve diğer sinir hücrelerinden aldıkları bilgileri kendi sinir hücrelerine aktarırken, hücre gövdesi ise dentritten aldığı bilgileri toplar ve aksona gönderir. Aksonlara aktarılan bu bilgiler de diğer sinir hücrelerine iletilir. Aksonlar her sinir hücresinde taktır. Sinaps, aksondan alınan bilgilerin diğer nöronun dentritine iletmek için bulunan bağlantı noktalarıdır. Bir sinir hücresinden diğer sinir hücresine bilgi aktarımı bu şekilde özetlenebilir [93].


Biyolojik sinir sistemindeki bu yapı örnek alınarak yapay sinir sistemleri oluşturulmuştur. Kısacası yapay sinir ağları biyolojik sinir ağlarının taklit edilmiş bir simülasyonudur denilebilir. Her ne kadar biyolojik sinir ağları taklit edilmiş olsa da insan beyninde bulunan milyonlarca nöron

ve trilyonlarca sinapsın oluşturduğu verimliliğe ulaşamamıştır.



Şekil 2.7. Biyolojik Nöron Yapısı [120]


İnsan beyninin çalışma yapısını taklit ederek biyolojik sinir ağlarının matematiksel modellemesi şeklinde oluşturulan yapıya yapay sinir ağları denilmektedir. Biyolojik sinir ağlarında bulunan nöronlara benzer olarak düğümleri bulunmaktadır. Bu düğümler yapay nöron şeklinde düşünülebilir. Asıl görevi bilgiyi işlemek olan YSA'lar birçok alanda kullanılabilmektedir. İnsanlardaki davranış kontrolünün hayvan ve makinelerde de uygulanmasından tahminlemeye, veri sıkıştırma gibi mühendislik çalışmalarına kadar birçok alanda yaygın olarak kullanılmaktadır [94].



Şekil 2.8. Yapay Sinir Hücresi [121]

Şekilde de görüldüğü gibi yapay sinir hücreleri; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 ana parçadan oluşmaktadır. Bu ana parçaları özetleyecek olursak, öğrenilmesi istenen bilgiler girdiler aracılığı ile alınmaktadır. Bu bilgiler farklı bir hücreden de gelebilir. Böylece alınan bilgi yapay sinir hücresine gönderilmiştir. Gelen girdi değerinin öz ağırlığının çarpılarak toplanması toplama fonksiyonu ile gerçekleştirilir. Her

YSA kendi kullanacağı toplama fonksiyonunu seçebilir [93]. Bu işlemler sonucunda net çıkışı hesaplamak ve nöron çıkışını verebilmek için aktivasyon fonksiyonu kullanılmaktadır. Aktivasyon fonksiyonu genellikle nonlinear bir fonksiyon şeklindedir [95].



Şekil 2.9. Yapay Sinir Ağı Hücresi [95]

Şekilde belirtilen b bias değişkenidir. Eşik değerini ifade etmektedir.

Nöron çıkışı;

$$y = f(w \cdot x + b) \quad [95] \quad (1.6)$$

şeklinde hesaplanmaktadır. n giriş sayısı, x giriş matrisi ve w ağırlık matrisi olmak üzere;

$$w = w_1, w_2, w_3, \dots, w_n \quad [95] \quad (1.7)$$

$$x = x_1, x_2, x_3, \dots, x_n \quad [95] \quad (1.8)$$

$$\text{net} = \sum_{i=1}^n w_i x_i + b$$


ve $y = f(\text{net})$

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

Aktivasyon fonksiyonu f seçimi kullanılacak probleme göre belirlenir. Tangent-Sigmoid (tansig) aktivasyon fonksiyonu çeşitlerinden biri olup Tansig fonksiyonunda toplam girişe bağımlı olarak $[-1,1]$ aralığında doğrusal olmayan bir değişim mevcuttur. Hiperbolik-tangent da denilmektedir [96].


$$a = \frac{2}{1 + e^{(-2n)}} - 1 \quad (1.9)$$

a nöron giriş çıkış ifadesidir [96].



Şekil 2.10. Tangent-Sigmoid Fonksiyonu Eğrisi [96]

Yapay sinir ağları birden fazla yapay sinir hücrelerinden oluşmaktadır. Biyolojik sinir ağlarını taklit etden YSA'nın katmanları bulunmaktadır. En genel tabirle YSA; giriş katmanı, ara katman ve çıkış katmanı olmak üzere 3 katmandan oluşmaktadır.



Şekil 2.11. YSA'nın Genel Yapısı

Giriş katmanı ilk katman olup dışarıdan bilgileri almakla görevli katmandır. Bu katman bilgileri alır fakat işlemez. Ara katman gizli katman olarak da adlandırılmakta olup bir YSA da birden fazla olabildiği gibi bazı YSA'larda hiç bulunmayadabilir. Giriş katmanından gelen bilgileri işleyerek çıkış katmanına göndermekle görevlidir. Çıkış katmanı ise YSA'da bulunan son katmandır. Ara katmandan gelen bilgi işlenerek çıkış için bilgi üretmektedir [90].


2.5.2. Yapay Sinir Ağı Modelleri

2.5.2.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı

Girdi ve çıktı katmanlarından oluşan YSA'da birden fazla girdi değeri ve bir çıktı değeri

bulunmakta olup çıktılar girdi değerleri ile ilişkilidir. Tek katmanlı YSA'da eşik değeri daima 1 değerini alır. Doğrusal bir sınıflandırıcı olarak kabul edildiğinden doğrusal olmayan problemleri çözmemektedir. Bu katmanın en büyük eksikliği budur [93].

Girdi işaretleri ve ağırlıklar hesaplanıp çıktı sonucu bulunur. Böylece bu çıktı yapay sinir hücrelerine iletilir [97].



Şekil 2.12. Tek Katmanlı Yapay Sinir Ağı

Giriş katmanında veri üzerinde hiçbir işlem yapılmadan çıkış katmanına iletilmesi sebebiyle bu ağ en basit ve temel ağ yapısında bulunmaktadır [90].




Şekil 2.13. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı

2.5.2.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

Doğrusal olmayan ilişkilerin olduğu problemlerde daha gelişmiş modellere ihtiyaç vardır. Çok katmanlı YSA buna örnek olup bu ağlarda girdi, çıkış ve ara katman olmak üzere 3 katman bulunmaktadır. Dışarıdan gelen bilgi giriş katmanı ile alınıp işlenmeden ara katmana iletilir. Ara katman probleme göre birden fazla olabilmektedir. İşlenen bilgi çıkış katmanına gönderilmektedir. Çıkış katmanında üretilen sonuç beklenen sonuç ile kıyaslanır. İkisi arasındaki fark geriye doğru dağıtılarak ağırlıkların değiştirilmesine geriye doğru hesaplama denilmektedir [97]. Geriye doğru yapılan hesaplamalar sonucunda hata en aza indirgenene kadar ağırlık güncellemesi yapılmaktadır [93].

İleri beslemeleri YSA'larda işlemler girişten çıkışa doğru ilerlediğinden gecikme oluşmamaktadır [90].




Şekil 2.14. Çok Katmanlı Yapay Sinir Ağı

Bu YSA'lara örnek olarak Çok Katmanlı Algılayıcılar verilebilir [93].

2.5.2.3. Geri Beslemeli Yapay Sinir Ağı

Geri beslemeli YSA'larda adından da anlaşıldığı üzere geriye doğru bir besleme mevcuttur. Bu YSA'da ara katmandaki veya çıkıştaki işlenmiş bilgiler bir önceki katmana doğru geri besleme yapılmaktadır. İleri beslemeli YSA'larda bir gecikme söz konusu değilken bu YSA'da gecikmeler olmaktadır. ϵ gecikme süresini ifade ederse, t anındaki çıkış $o(t)$ ise ϵ gecikme ile çıkış $o(t + \epsilon)$ olmaktadır. Dinamik hafızaları olan bu YSA'lar hem çıkış hem de bir önceki girişi yansıtabildiğinden önceden tahmin uygulamalarında tercih edilmektedirler [90].



Şekil 2.15. Geri Beslemeli Yapay Sinir Ağı

Geri beslemeli YSA'lara örnek olarak Öndüzenleyici Haritalar (SOM) ve Hopfield verilebilir [93].

2.6. YSA'da Öğrenme

Danışmanlı öğrenmede girdi ve çıktı değerleri ağı sunulmakta olup gerçek çıkış ile istenen çıkış arasında karşılaştırma yapılır. Ağırlıkların da hesaplanması ve çıkışlar arasındaki farklarla hatalar en aza indirgenmeye çalışılır. Doğruluk artıp hata azalana kadar ağırlık üzerinde güncelleme yapılmaktadır. Çok katmanlı YSA bu öğrenme yöntemine örnek verilebilir [93].

Danışmansız öğrenmede ise, girdiler arasındaki ilişkilere göre bağlantı ağırlıkları düzenlenmekte olup giriş modelleri ve örneklerini sınıflandırıp bir kural oluşturmaktadır. Ağırlıklar bu kurala göre sınıflandırmayı yapabilir şekilde ayarlanır. Sadece girdi değerleri sunularak çıktı değeri girilmeden öğrenme yöntemi oluşturulur. K-means ve SOM bu öğrenme yöntemine örnek olarak verilebilir [93].

Tensorflow; makine öğrenimi, derin öğrenme ve diğer istatistiksel tahmine dayalı işleri çalıştırmak için kullanılan açık kaynaklı bir çerçeve olup bu tür durumlarda uygulamaları geliştirme ve yürütme süreçlerini kolaylaştırmak amacıyla tasarlanıp geliştirilmiş bulunmaktadır [98].

Zorlu gerçek dünya sorunlarını çözmek için makine öğrenimi kullanılmaktadır. Makine öğrenimi modelleri geliştirip eğitmemize yardımcı olan tensorflow makine öğrenimi için uçtan uca açık kaynaklı bir platformdur [99].

İlk olarak Google ekibi tarafından makine ve derin sinir ağları araştırması için geliştirilen tensorflow hem araştırma hem de üretim için kullanılmaktadır. Veri akış grafikleri kullanılarak sayısal hesaplama yapmayı sağlar. Çapraz bir platform olan Tensorflow birçok platformda çalışabilmektedir [100].

Yapay sinir ağları için bir python arabirimi sağlamakta olan açık kaynaklı bir yazılım kitaplığıdır. Derin sinir ağları ile hızlı deneyler sağlamakta olup kullanıcı dostudur. Derin sinir ağı kodları yazarken kodlamayı basitleştirmek amacıyla görüntü ve metin verileriyle çalışmayı kolaylaştıran katmanlar ve uygulamalar içermektedir. GPU (Grafik İşleme Birimleri) ve TPU (Tensör İşleme Birimleri) kümeleri üzerinde derin öğrenme modellerinin kullanımını da sağlamaktadır [102].

Keras, bilişsel yükü azaltmak için tutarlı ve basit API'ler sunarak sık kullanım durumları için gereken kullanıcı sayısını en aza indirerek açık hata mesajları sağlamaktadır. Kapsamlı dökümantasyona ve geliştirici kılavuzlarına sahip olan Keras daha fazla fikri daha hızlı denememizi sağlamaktadır [101].

Büyük GPU kümelerine veya TPU bölmesine ölçeklenebilen Keras, TensorFlow üzerine inşa edilmiştir. TensorFlow 2.0 ekosisteminin merkezi bir parçası olan Keras, veri yönetiminden

hiperparametre eğitimine ve dağıtım çözümlerine kadar makine öğrenimi iş akışının her adımını kapsamaktadır. Deney döngülerini hızlandırmak için yüksek düzeyde kolaylık sunduğu gibi rastgele araştırma fikirlerini uygulamak için düşük düzeyde esnekliğe de sahiptir [101].

Kerasta sinir ağlarının en temel yapı taşı olan katmanlar her katman için bulunduğu katmanda girdi bilgilerini alıp gerekli hesaplamaları yapar. Ardından üretilen bilgileri sonraki katmana iletir. Katmanlar arası bilgi akışı birinin ürettiği sonuç diğerinin girdisi olacak şekildedir [108].

Bir katman tensor-in, tensor-out hesaplama fonksiyonun ve katmanın ağırlığının tutulduğu TensorFlow değişkenlerinden oluşmaktadır. Katman eğitim süresince veri girişi olduğunda güncellenip saklanır [109]. Projemizde Aktivasyon, Convolution2D, Dropout, Conv2D, AveragePooling2D, BatchNormalization, GlobalAveragePooling2D, Flatten, Input (MaxPooling2D, SeparableConv2D) kullanılmıştır.

Eğitimin çeşitli aşamalarında eylemler gerçekleştirebilen bir nesne olan callbacks, bu işlemi eğitimdeki bir dönemin başında veya sonunda gerçekleştirebilir. Modelimizi periyodik olarak diske kaydetmek, erken durdurma, metrikleri izlemek için her eğitimden sonra TensorBoard logları yazma, eğitim sırasında bir modelin dâhili durumlarına ve istatistiklerine ilişkin bir görünüm elde edebilmek amaçları için kullanılabilir. Bir modelin yöntemine geri aramaların listesi iletilir ve geri aramalar ilgili yöntemleri eğitimin her aşamasında çağırabilmektedir [103].

CSVLogger, bu geri arama ile devir sayısı sonuçları bir CSV dosyasına aktarılmaktadır. Bir dize olarak temsil edilebilen tüm değerleri desteklemektedir [104].


Model Check Point, keras modelini veya model ağırlıklarını belirli bir sıklıkla kaydetmek için kullanılır. Bir modeli veya ağırlıkları belirli aralıklarla kaydetmek için kullanılan eğitimle bağlantılı olarak kullanılır. Bu durumda model veya ağırlıklar daha sonra kaydedilen durumdan eğitime devam etmek için yüklenebilir [105].

Erken durdurma, izlenen bir metrik gelişmeyi durdurduğunda eğitimin durdurulmasını sağlar. Örnek verecek olursak, bir eğitimin amacının kaybı en aza indirmek olduğu düşünüldüğünde kaybın artıp azalmadığını kontrol ederek artık azalmadığı görüldüğünde eğitimi sona erdirir [106].

Modeller öğrenme durgunlaştığında öğrenme oranını azaltmanın faydalı olduğunu belirlemiştir. ReduceLROnPlateau ile metriği izler ve gelişmesi durduğunda öğrenme oranını azaltır. Öğrenme bir miktar izlendikten sonra bu dönem boyunca herhangi bir gelişme görülmezse öğrenme oranı düşer [107].


2.6.1.Yapay Sinir Ağı Modelleri

CNN yani evrişimli sinir ağıları çok katmanlı algılayıcı mimarisini kullanan bir derin öğrenme yöntemi olup CV ve görüntü analizi ile ilgili çalışmalarda sıklıkla kullanılmaktadır. Evrişimli adını alma sebebi ise ağıın matematikte evrişim adı verilen doğrusal bir işlemi kullanıyor olmasıdır. Evrişim işlemi bir ya da daha fazla katmanda kullanılabilmektedir. Karmaşık yapıları tanımada oldukça başarılı olan CNN'in çalışma prensibini standart YSA'dan farklıdır. Bir katmanda bulunan nöron görüntüdeki küçük bir alana yoğunlaşır ve özellik arar. Diğer nöronlar ise görüntüdeki farklı bölümlerin özelliklerini aramaya başlar [110]. CNN'nin en önemli iki amacından birincisi özellik çıkarma ikincisi çıkarılan özelliklerden tahmin yapmaktır.




Şekil 2.16. Evrişimi Tasvir Eden CNN Mimarisi, Havuzlama ve Tam Bağlantılı Katmanlar [122]

Birden çok farklı katmana sahip olan CNN'nin yapısı yukarıdaki şekilde gösterilmektedir. Giriş katmanı, gizli katmanlar ve sonuç katmanı bulunmaktadır. Bir görüntü alınarak çalışmaya başlanır. İlk gizli katmanda kenarlar, ağız, burun, göz gibi basit kalıplar öğrenilir. Ardından görüntü daha belirgin özellikleri öğrenen bir sonraki katmana iletilmektedir [110].




Şekil 2.17. Evrişimsel Sinir Ağı Yapısı [126]

Evrişim işlemi evrişimsel sinir ağı için oldukça öneme sahiptir. Evrişim işlemi ile görüntülerdeki kenarlar, eğriler, köşeler gibi özellikler çıkarılmaktadır [116].



Şekil 2.18. Evrişimli İşlem Örneği [116]

6x6 gri tonlamalı bir resimde kenarların tespit edilebilmesi için 3x3 filtre kullandığımızda aşağıdaki gibi evrişim işlemi gerçekleştirilir ve çıktı 4x4 boyutunda bir matris olur. Filtre sağa kaydırılarak devam eder ve işlemler şekilde olduğu gibi yapılmaktadır [116].




Şekil 2.19. Evrişim İşlemi [116]

CNN de MLP gibi geri yayılım yöntemiyle eğitilmektedir. CNN’ler birkaç ana katmanın tekrarı şeklinde belirlenmiş olup en çok kullanılan katmanlar;

2.6.1.1. Evrişim Katmanı

Giriş görüntülerinden çeşitli özellikleri çıkarmak için kullanılan “Evrişim Katmanı” giriş görüntüsü ile belirli bir MxM boyutunda bir filtre kullanılarak matematiksel işlem gerçekleştirilir. Bu filtre giriş görüntüsü üzerinde kaydırılarak MxM filtre boyutuna göre filtre ile görüntünün parçaları arasında olmaktadır. Böylece köşe ve kenarlar hakkında bilgi veren “Özellik Haritası” çıkarılmaktadır. Ardından bu özellik haritası ile diğer özellikleri öğrenmek amacıyla diğer katmanlar beslenmektedir [111].

CNN’nin ilk gizli katmanı olan evrişim katmanında bir görüntü filtrelenmiş görüntülerden oluşan bir yığın haline gelir ve filtreleme ile daha küçük bir ağırlık kümesi oluşturularak sonraki katmana geçmek için giriş görüntüsüyle birleştirilmektedirler.



Şekil 2.20. 3 Kanallı Görüntüde 2 Adet 3 Kanallı Filtre ile Evrişim [116]

2.6.1.2. Havuzlama Katmanı

Evrişim katmanından sonra gelen havuzlama katmanı önceki katmandan elde edilen görüntü yığınlarını ve parametrelerini azaltmak amacıyla kullanılmaktadır. 2 veya 3 boyutunda bir pencere evrişim katmanlarından filtrelenmiş görüntüler boyunca hareket ettirilir. Her geçişte pencerede kalan değerlerin geri kalanı atılırken maksimum değer korunur. Sonuçta genellikle orijinal filtrelenmiş görüntünün %75'i olan daha küçültülmüş görüntüler verilmiş olur [110].

Bu katmanın en önemli amacı hesaplama maliyetini azaltmak için özellik haritasının boyutunu azaltmaktır. Bu da katmanlar arası bağlantılar azaltılarak gerçekleştirilir [111].

Kullanılan yöntemle göre iki çeşit havuzlama katmanı vardır. Maksimum havuzlamada her havuzlama işlemi geçerli matrisin maksimum değerini seçerken, ortalama havuzlama da ise her havuzlama işleminde geçerli matrisin değerlerinin ortalaması alınır.

2.6.1.3. ReLU

Aktifleştirme katmanı olarak da bilinen bu katman giriş verisine etki ederek negatifleri sıfıra çekmektedir [112]. CNN mimarisinde ikinci veya dördüncü katmanda bulunan ReLU katmanının amacı tüm negatif değerleri sıfıra çekip tüm pozitif değerleri ise koruyarak görüntünün piksellerini normalleştirmektir [110].

2.6.1.4. Tam Bağlantı Katmanı (Fully Connected Layer)

CNN için çıktı katmanı olan bu katman diğer katmanların bir tekrarı olsa bile her zaman CNN'nin sonunda bulunmaktadır. Bu katmanda bulunan tüm nöronlar standart sinir ağına benzer şekilde önceki katmanın tüm nöronlarına bağlıdır [110]. Bu katmanda amaç sınıf skorları gibi hedefleri optimize etmektir [113].

2.6.1.5. Dropout Katmanı

Büyük verilerle eğitim yapıldığında ağda ezberleme olayının gerçekleşmesini engellemek amacıyla kullanılan bu katmanda temel mantık ağdaki bazı düğümlerin kaldırılmasıdır [112]. Bir model eğitim verileri üzerinde çok iyi çalıştığında “Aşırı Uyum” olayı ortaya çıkabilir. Bu durum modelin performansında olumsuz bir etkiye sebep olabilmektedir. Bu sorunun önüne geçmek amacıyla eğitim sırasında bazı düğümler ağdan çıkarılır ve modelin boyutunun küçüldüğü bir dropout katmanı oluşturulur [111].

2.6.1.6. Düzleştirme Katmanı

Sinir ağlarına iletilecek verinin uygun formata getirilmesi için kullanılan katmandır. Sinir ağları genellikle tek boyutlu dizilerden beslendiğinden dolayı matris formatında olan verinin vektörel dönüşümle format dönüşümü sağlanmış olur [115].

2.6.1.7. Padding İşlemi

$N \times N$ bir görüntüye $F \times F$ bir filtre uygulandığında evrişim işleminden dolayı görüntünün boyutu $(N - F + 1) \times (N - F + 1)$ olarak değişmektedir. Örneğin (6×6) bir görüntüye (2×2) bir filtre uygulandığında evrişim işleminden sonra oluşacak görüntünün yeni boyutu $(6 - 2 + 1) \times (6 - 2 + 1)$ yani (5×5) olacaktır. Bu sebeple görüntü küçülecektir. Padding işlemi ile bu küçülmüş görüntünün kenar ve köşeleri sıfır ile doldurulmaktadır. Böylece görüntünün orijinal boyutu korunmuş olmaktadır [114].


3. BULGULAR VE TARTIŞMA

3.1. Yüz İfadesi Tanıma Aşamaları

Duygu analizinin gerçekleştirilebilmesi için izlenecek adımlar sıralandığında ilk olarak görüntünün elde edilmesi gerekmektedir. Bunun için fiziksel bir donanım ihtiyacı vardır. Elde edilen görüntünün işlenip özelliklerinin çıkarılması ve ardından sınıflandırılması gerekmektedir.


Görüntüler statik görüntüler veya görüntü dizilerinden oluşabilmektedir. Görüntüyü almak için kamera kullanılır. Kamera ile alınan görüntüde yüz görüntüsünün alınabilmesi için haar sınıflandırıcısı kullanılmaktadır. Bu işlem OpenCV aracılığıyla gerçekleştirilir. İnsan yüzü algılamada kullanılan haar özellikleri haar sınıflandırıcısının ana parçası olup, haar öznitelikleri görüntüdeki öznitelikleri tespit etmek amacıyla kullanılmaktadır. Her özellik beyaz dikdörtgenin altındaki piksel sayısının siyah dikdörtgenin altındaki piksel sayısından çıkarılmasıyla hesaplanarak üretilen tek bir değerden oluşmaktadır [77].

Aşağıdaki görsel incelendiğinde ilk özelliğin göz bölgesinin burun ve yanak bölgelerine oranla daha koyu olmasından dolayı bu bölgeye odaklandığı, ikinci özelliğin ise burun köprüsünün göz bölgesinden daha açık olmasına odaklandığı söylenebilir.



Şekil 3.1. Haar Cascade Görsel [134]

Yüz tanıma aşamalarını sıralayacak olursak aşağıdaki görselde de belirtildiği gibi ilk olarak görsel elde edilir ve bu görsel üzerinde özellik çıkarma işlemleri gerçekleştirilir. Özellik çıkarma işlemleri tamamlandıktan sonra aynı özniteliklere sahip görseller sınıflandırılmaktadır.




Şekil 3.2. Genel Akış Diyagramı

Bu çalışmada 7 farklı duygu için sınıflandırma yapılması amacıyla bir evrişimsel sinir ağı (CNN) önerilmiştir ve FER2013 veri kümesi önerilen sinir ağı üzerinde eğitilmiştir.

3.2. Konvolüsyon Sinir Ağı Yapısı (CNN)

CNN modeli Evrişim (Konvolüsyon), ReLU, havuzlama ve sonuç olarak softmax katmanlarından oluşturulmuştur. Önerilen modelde ilk optimizasyon fonksiyonu olarak “adam” kullanılmıştır. Ardından aynı modelde optizmizasyon fonksiyonu olarak ”sgd” kullanılmıştır. İki farklı optimizasyon fonksiyonu için de başarı oranları elde edilip karşılaştırmaları yapılmıştır. Aşağıdaki görselde hazırlanan ve kullanılan CNN modeli yer almaktadır.



Şekil 3.3. Hazırlanan CNN Modeli


Şekilde de görüldüğü gibi hazırlanan modelde evrişim (konvolüsyon), ReLU, havuzlama ve tam bağlantı katmanları bulunmakta olup son katman olarak da softmax kullanılmıştır. Softmax

ile imgeler sınıflandırılmaktadır. Bu model kullanılarak seçtiğimiz veri kümesi ile test işlemleri gerçekleştirilip başarımları karşılaştırılacaktır.

Yapay sinir ağının en temel katmanı evrişim katmanıdır. Bu katmanda gerçekleştirilen dönüşüm işlemi 2×2 , 3×3 gibi bir filtrelerin görüntü üzerinde gezinmesi işlemidir. Kendisinden önceki katmandan gelen görüntülere uygulayarak filtreler sayesinde çıkış verisi gerçekleştirilmektedir. Bu işlemler sonucunda özellik haritası çıkarılmış olmaktadır. Çalışmada 3×3 boyutunda bir filtre ile konvolüsyon işlemi gerçekleştirilmiştir. Görüntü matrisinin tümünde yapılan bu işlem her kanal üzerinde yapılarak toplamaları özellik haritasını oluşturmaktadır.

Görüntüdeki parazitlerin temizlenmesi, parlaklık değişimi gibi durumlar için normalleştirme işlemi gerçekleştirilir. Renk ve histogram normalleştirme yapılmaktadır. Bu işlemlerin ardından özellik çıkarma işlemi gerçekleştirilir. Normalizasyon işlemi genellikle çok katmanlı derin sinir ağlarında kullanılıp gizli katmanlar arasında kovaryansı azaltmak amacıyla kullanılmaktadır.


Birçok katmana sahip olan sinir ağını eğitmek başlangıçtaki rastgele ağırlıklara ve algoritmanın yapılandırmasına duyarlı olabildiklerinden dolayı oldukça zordur. Toplu normalleştirme ile katmanların girdilerini yeniden merkezleyip ölçeklendirme yoluna gidilir. Böylece yapay sinir ağı daha hızlı ve kararlı hale toplu normalizasyon yöntemi ile getirilmiş olmaktadır. Her katmanın girdilerinin ortalamaları ve varyansları sabitlenmiş olmaktadır. Toplu normalleştirme yöntemini tüm eğitim kümesi üzerinde gerçekleştirilecektir [135]. CNN mimarisinde kullanılan ReLU katmanının amacı tüm negatif değerleri sıfıra çekip tüm pozitif değerleri ise koruyarak görüntünün piksellerini normalleştirmektir [110]. Aktifleştirme katmanı olarak da bilinen bu katman giriş verisine etki ederek negatifleri sıfıra çekmektedir [112]. Bir nöronun aktif olup olmadığına karar verilmesi gerekmektedir. Bir nöron negatif değer üretirse aktive edilemeyeceği anlamına geldiğinden çalışmamızda ReLU fonksiyonu kullanımı tercih edilmiştir.



Şekil 3.4. ReLU Grafiği

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (1.10)$$

ReLU katmanından sonra gerçekleştirilen havuzlamaların temel amacı sonraki katman için genişlik ve yükseklik boyutunu indirmektedir. Bu işlem ile bir sonraki katman için hesaplama yükü azalır ve ezberlemenin önüne geçilir. Belirli filtrelerle gerçekleştirilen havuzlama yöntemlerinden maksimum havuzlama daha iyi performans göstermesi sebebiyle bu çalışmada da tercih edilmiştir. Aşağıdaki şekilde her çeyrekte en yüksek değer alınarak maksimum havuzlama işlemi yapılırken her çeyrekteki değerlerin ortalaması alınarak da ortalama havuzlama yapılmaktadır.




Şekil 3.5. İki Tür Havuzlama İşlemi [129]

Modelimizde eğitim yaparken kullanılan veri kümesi üzerinde ezber yapma durumu

olabilmektedir. Eğitim kümesinde yüksek skor alsak da test verileri gönderildiğine çok düşük skorlar alınmaktadır. Bu durumun oluşması aşırı uyum olarak adlandırılmaktadır. Eğitim yapılırken aşırı uyma olayının önüne geçmemiz ve doğru tahminler yapmamız gerekmektedir. Aşırı uyma sorununun önüne geçmek için dropout katmanı kullanılmaktadır. Büyük verilerle eğitim yapıldığında ağda ezberleme olayının gerçekleşmesini engellemek amacıyla kullanılan bu katmandaki temel mantık ağdaki bazı düğümlerin kaldırılmasıdır [112].

Şekilde ilk görüntü standart bir YSA iken diğerinde dropout katmanından sonraki ağ yapısı gösterilmiştir.



Şekil 3.6. Dropout Katmanında Ağ Yapısı [112]

3.3. Veritabanı

Yapılan çalışmada insan yüz ifadelerini barındıran FER2013 veri kümesi kullanılmıştır. Bu küme eğitim ve test verileri olmak üzere toplamda 35887 veri içermektedir. Eğitim kümesi tüm ifadeler içinde olmak üzere 28709 örnek içermektedir. 7178 örnek ise test kümesini oluşturmaktadır. Test ve eğitim kümesinde her yüz ifadesine göre örnek verilerin sayısı aşağıdaki tabloda gösterilmiştir. İfadelerdeki örnek sayısının fazla olması doğruluk oranımızı etkilemektedir. Her sınıf için kendi kategorilerine uygun eğitim örneği sayısı yüz tanımda oldukça önemli bir etkiye sahiptir.

Çizelge 3.1. Fer2013 Veri Kümesi Eğitim ve Test Veri Sayıları

Yüz İfadesi	Eğitim Kümesi Örnekleri	Test Kümesi Örnekleri
Kızgın	3995	958
İğrenmiş	436	111
Korkmuş	4097	1024
Mutlu	7215	1774
Üzgün	4830	1247
Şaşırmış	3171	831
Doğal	4965	1233

Çalışmada kullanılan veri kümesinde veriler eğitim ve test verileri olarak ikiye ayrılmış olup görsellerin %80'i eğitim, %20'si ise test için ayrılmıştır. Aşağıdaki şekilde veri kümesinde bulunan örnek görüntüler bulunmaktadır.

**Şekil 3.7.** FER-2013 Veri Kümesi Duygu Örnekleri**Çizelge 3.2.** Veri Kümesindeki İmge Türleri ve Oranları

Etiket	Duygu	Sayısı	Oranı
0	Kızgın	4953	0.1380
1	İğrenmiş	547	0.0152
2	Korkmuş	5121	0.1427
3	Mutlu	8989	0.2505
4	Üzgün	6077	0.1693
5	Şaşırmış	4002	0.1115
6	Doğal	6198	0.1727

Tablo incelendiğinde veri kümesinde yer alan 7 farklı yüz ifadesinin oranları eşit olmayıp farklı dağılım göstermiştir. Veri sayısı en az olan ifade iğrenmiş duygu ifadesi iken, en çok olan ifade ise mutluluk duygu ifadesidir.

3.4. Eğitim Sonuçları

Çalışma yapılırken doğruluk oranını artırmada kullanılacak verilerin sayısının fazla olması önemli bir etkidir. Bu sebeple büyük miktarda veri içeren veri kümeleri araştırılıp seçildi. Bu çalışmada Kaggle Fer2013 veri kümesi kullanılmıştır. Kaggle Fer 2013 veri kümesinde kullanılan veriler 48x48 piksel gri tonlamalı yüz görüntülerinden oluşmaktadır.

7 temel duyguya sahip yüz ifadesi 0'dan 6'ya kadar numaralandırma yapılarak kategorize edilir. Her duygu kendine ait belirlenmiş numara ile etiketlenilmektedir.

Çizelge 3.3. Etiket ile Duygu Karşılığı

Etiket	Duygu
0	Kızgın
1	İğrenmiş
2	Korkmuş
3	Mutlu
4	Üzgün
5	Şaşırmış
6	Doğal


Veri kümesinde her duygu için belirgin olarak bulunan veriler ayarlandıktan sonra bu veri kümesi için CNN yapay sinir ağı oluşturulmuştur. Çalışma yapılırken Keras ve Tensorflow kütüphanelerinin kolayca kullanım imkânı sağlamasından dolayı python programlama dili tercih edilmiştir. Katmanlar, düğüm sayıları, aktivasyon katmanları belirlenmiş olup bunların arasına havuzlama katmanları da eklenmiştir. Burada amaç yeterince özellik çıkarabilmektir. Aktivasyon fonksiyonu olarak ReLU kullanılırken çıkış katmanında ise Softmax kullanılmaktadır. Gri formatta olan veri kümesi hazırlanan CNN modelinden geçirildikten sonra elde edilen özellikler ağda bulunan softmax sınıflandırıcı ile sınıflandırılmıştır.

Softmax fonksiyonu, bir sinir ağı modelinde çok terimli olasılık dağılımı mevcutsa yani ikiden fazla sınıf etiketinin olduğu ağlarda çıktı katmanında aktivasyon işlevi olarak kullanılmaktadır [125].

Test işlemi ise veri kümesinde bulunan duygular hakkında bilgi vermekte ve tüm verilerin sınıf bilgilerini içermektedir. Test işlemi de bu değerlere göre yapılmaktadır. Sinir ağında aşırı

öğrenmeyi engellemek amacıyla Dropout kullanılmıştır. Bu yaklaşımlar sonucunda 7 temel duygu için doğruluk oranının en verimli şekilde hesaplanması amaçlanmıştır.

Optimizasyon fonksiyonu olarak ilk “Adam” kullanılmıştır. Ardından aynı modelde “SGD” optimizasyon fonksiyonu kullanılarak karşılaştırmaları yapılmıştır. “Adam” fonksiyonunun tercih edilme sebebi hesaplama açısından verimli olup az bellek gereksinimi duyması ve yeniden ölçeklendirmelerde veriler açısından büyük problemler için çok uygun olmasıdır [124]. Adam optimizasyon fonksiyonu kullanılarak gerçekleştirilen eğitim sonucunda doğruluk ve kayıp grafikleri aşağıdaki gibidir.




Şekil 3.8. Adam Optimizasyon Fonksiyonu Kullanılarak Oluşturulan Doğruluk-Devir

Çizelge 3.4. Adam Optimizasyon Fonksiyonu Doğruluk Değerleri

Devir (Epoch)	Doğrululuk Değeri (Accuracy)
10	0,5699
20	0,6066
30	0,6231
40	0,6464
50	0,6464
60	0,6576
70	0,6871
80	0,69
90	0,6956

100	0,6971
110	0,6996



Şekil 3.9. Adam Optimizasyon Fonksiyonu Kullanılarak Oluşturulan Kayıp-Devir

Çizelge 3.5. Adam Optimizasyon Fonksiyonu Kayıp Değerleri

Devir (Epoch)	Kayıp Değeri (Loss) (Adam)
10	1,15
20	1,058
30	1,008
40	0,9727
50	0,9446
60	0,9249
70	0,8468
80	0,83
90	0,8192
100	0,8161
110	0,8128

SGD optimizasyon fonksiyonu ise; uygun düzgünlük özelliklerine sahip bir objektif işlevi optimize etmek için kullanılan yinelemeli bir yöntemdir. Yüksek boyutlu optimizasyon

problemlerinde bu, işlem yükünü azaltır ve daha düşük yakınsama oranı için daha hızlı yinelemeler sağlar [131]. SGD optimizasyon fonksiyonu kullanılarak gerçekleştirilen eğitim sonucunda doğruluk ve kayıp tablosu aşağıdaki gibidir.

Çizelge 3.6. SGD Optimizasyon Fonksiyonu Doğruluk Değerleri

Devir (Epoch)	Doğruluk Değeri (Accuracy)
10	0,5778
20	0,6558
30	0,7188
40	0,7708
50	0,8161
60	0,8547
70	0,8692
80	0,8957
90	0,9269
100	0,9269
110	0,9298

Çizelge 3.7. SGD Optimizasyon Fonksiyonu Kayıp Değerleri

Devir (Epoch)	Kayıp Değeri (Loss) (Adam)
10	1,15
20	1,058
30	1,008
40	0,9727
50	0,9446
60	0,9249
70	0,8468
80	0,83
90	0,8192
100	0,8161
110	0,8128

4. SONUÇ

İnsanlar arası iletişimde oldukça öneme sahip olan sözsüz iletişimde yüz ifadeleri büyük anlam taşımaktadır. Yüz ifadelerinin analizi gelişen teknolojiyle makinalar tarafından da anlamlandırılabilir. İnsanların ruhsal durumunu belirten yüz ifadelerinin analizi eğitimden güvenliğe kadar birçok alanda ihtiyaç haline gelmiş durumdadır.

Bu çalışmaya başlarken en etkili teknik ve sınıflandırma yöntemlerin araştırması yapıldı. Doğruluk oranını artırmada kullanılacak verilerin sayısının fazla olması önemli bir etken olduğundan büyük miktarda veri içeren veri kümeleri araştırılıp seçildi. Bu çalışmada Kaggle Fer2013 veri kümesi kullanılmıştır. Kamera aracılığı ile alınan görüntünün herhangi bir kullanıcıya ihtiyacı olmadan yüzün özelliklerini çıkarıp 7 temel duyguya göre sınıflandırılması sağlanmıştır. Bu sınıflandırma yapılırken yüz ifadelerinde oluşan değişimler referans alınıp hangi sınıfa uygun ise oranın özelliği verilmiştir.

Bu çalışma ile insanların yüz ifadeleri anlamlandırılıp psikolojik durumlarının analizi yapılmış ve 7 psikolojik durum ele alınmıştır. OpenCV Haar sınıfı kullanılarak yüzler belirlenmiş ardından ise bu yüzlerin ifadeleri yapay sinir ağları ile eğitilerek anlamlandırılmış ve sınıflandırılmıştır.


Derin öğrenme mimarileri incelendiğinde bunların birçok katmandan oluştuğu görülmektedir. En sık kullanılan katmanlar ise derin sinir ağlarıdır. Son zamanlarda görüntü işleme alanında yapılan çalışmalar incelendiğinde başarı oranı yüksek olan yöntemler içinde evrişim yönteminin daha sık tercih edildiği görülmektedir. Bu çalışmamızda da evrişimsel sinir ağları yöntemi kullanılmaktadır.

Yapılan çalışmanın doğruluk oranı adam ve sgd optimizasyon fonksiyonları için sırasıyla %69 ve %92 olarak elde edilmiştir. Bazı duyguların net olmaması, sınıflarda bulunan verilerin az olması, bazı duygularda birkaç duyguyu birden barındıran ifadelerin olması gibi karmaşık durumlar doğruluk oranını olumsuz etkilemektedir. Yüz mimiklerinde birbirine benzeyen ifadelerin olmaması yani duygu karmaşıklığının önüne geçilmesi ve veri kümesinde bulunan görüntü sayılarının artırılması ile doğruluk oranı olumlu etkilenecektir.

Seçilen veri kümesinde 28709'u eğitim verisinden 7178'i ise test verisinden oluşan veriler bulunmaktadır. Eğitim sonucunda en yüksek doğruluk değerine sahip olan model seçilmiştir. Test verilerinde duygu etiketi bulunmamakta olup eğitimden sonra tahminlemesi yapılmaktadır.

Toplamda 7 duygu ifadesi için bakıldığında tümünün doğruluk oranı eşit çıkmamıştır. Bunun sebebi ise eğitim verilerinde bulunan veri miktarındaki farktır. Tüm başarı oranları değerlendirildiğinde %20'lik verilerin test edilmesiyle adam optimizasyon fonksiyonunda %69 ve

SGD optimizasyon fonksiyonunda ise %92 oranında başarımlar elde edilmiştir.



Şekil 4.1. Adam ve SGD Optimizasyon Fonksiyonu Kullanılarak Oluşturulan Kayıp-Devir

Makine öğrenimi alanında istatistiksel verilere ulaşabilmek amacıyla karşılaştırma matrisinden yararlanılır. Algoritmamızın performansını karşılaştırıp görselleştirdiğimiz bu tablo düzenine göre aşağıdaki çizelgede adam optimizasyon fonksiyonu kullanılarak duygulara göre başarımlar oranları aşağıdaki gibidir.

Çizelge 4.1. Karşılaştırma Matrisi Sonucu

Duygu	Test İşlemi Başarımlar Oranı
0	0.56
1	0.54
2	0.41
3	0.86
4	0.54
5	0.73
6	0.65

0 etiketiyle temsil edilen duygumuz kızgın duygu ifadesidir ve bunun doğruluk oranı 0.56 olarak belirlenmiştir. 1 etiketiyle temsil edilen duygumuz iğrenmiş duygu ifadesidir ve bunun

doğruluk oranı 0.54 olarak belirlenmiştir. 2 etiketiyle temsil edilen duygumuz korkmuş duygu ifadesidir ve bunun doğruluk oranı 0.41 olarak belirlenmiştir. 3 etiketiyle temsil edilen duygumuz mutlu duygu ifadesidir ve bunun doğruluk oranı 0.86 olarak belirlenmiştir. 4 etiketiyle temsil edilen duygumuz üzgün duygu ifadesidir ve bunun doğruluk oranı 0.54 olarak belirlenmiştir. 5 etiketiyle temsil edilen duygumuz şaşırmış duygu ifadesidir ve bunun doğruluk oranı 0.73 olarak belirlenmiştir. Son olarak 6 etiketiyle temsil edilen duygumuz doğal duygu ifadesidir ve bunun doğruluk oranı 0.65 olarak belirlenmiştir. Karşılaştırma matrisi incelendiğinde yüz hatlarının belirgin olmasının doğruluğu etkilediği düşünülmektedir. Aynı zamanda veri miktarının fazla olması da doğruluk oranını etkilemektedir. Bazı yüz ifadelerinin birbirine benzemesi modelin hatalı tahmin etmesine sebep olabilmektedir. Aşağıdaki tabloda ise Adam ve SGD optimizasyon fonksiyonu kullanıldığında elde edilen doğruluk oranları karşılaştırılmıştır. Her 10 devir için elde edilen değerler belirtilmiştir. Bu karşılaştırma sonucunda önerilen modelde SGD optimizasyon fonksiyonun Adam optimizasyon fonksiyonuna göre daha yüksek doğruluk oranı elde edilmiştir.

Çizelge 4.2. Adam-SGD Optimizasyon Fonksiyonu Doğruluk Oranı Karşılaştırması

Devir Sayısı	Adam	SGD
10	0,5699	0,5778
20	0,6066	0,6558
30	0,6231	0,7188
40	0,6464	0,7708
50	0,6464	0,8161
60	0,6576	0,8547
70	0,6871	0,8692
80	0,69	0,8957
90	0,6956	0,9269
100	0,6971	0,9269
110	0,6996	0,9298

Yapılan çalışmada görüntü işleme teknikleri ve yapay sinir ağında en çok kullanılan yaklaşımlar araştırılmış ve duygu analizi alanında yapılacak diğer çalışmalara kaynak oluşturulmuştur. Böylece ileriki zamanlarda kendi veri kümemiz de kullanılarak zenginleştirilip farklı CNN yöntemleri de kullanılarak daha yüksek başarılı çalışmalar yapmak için referans olacaktır.



Şekil 4.2. Farklı Duygulara Göre Yüz İfadeleri

5. KAYNAKLAR

- [1] ER, O. 2004. İnsan Yüzü Bulma ve Tanıma. Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- [2] Samtaş G, Gülesin, M, 2011. Sayısal Görüntü İşleme ve Farklı Alanlardaki Uygulamaları. Ejovoc (Electronic Journal of Vocational Colleges), 2(1), 85-97.
- [3] Öncü S, 2014. Bilgisayarlı Görü ve Ses Algılama Tekniği ile Hareketli Nesne Takibi. Yüksek Lisans Tezi, Bozok Üniversitesi Fen Bilimleri Enstitüsü, Yozgat.
- [4] Asmaz K, 2006. Görüntü İşleme ile İki Boyutlu Cisimlerden Grafik Modeller için Veri Eldesi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul
- [5] Bayrakdar S, Akgün D, Yücedağ İ, 2016. Yüz İfadelerinin Otomatik Analizi Üzerine Bir Literatür Çalışması. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 20(2): 383-398.
- [6] Chibelushi C C, Bourel F, 2002. Facial Expression Recognition: A Brief Tutorial Overview, CVonline: On-Line Compendium of Computer Vision. In Proceedings of the 13th Annual ACM International Conference on Multimedia (Vol. 5, pp. 669-676).
- [7] Darwin C, 1872. "Expression of the Emotions in Man and Animals", John Murray, London.
- [8] Ekman P, Friesen W V, 1971. Constants Across Cultures in the Face and Emotion, Journal of Personality and Social Psychology, 17(2), 124-129.
- [9] Ekman P, Friesen W V, 1978. Facial Action Coding System: A Technique for The Measurement of Facial Movement, Consulting Psychology Press.
- [10] Scherer K, Ekman P, 1982. Methods for Measuring Facial Action, Handbook of Methods in Nonverbal Behavior Research, Cambridge University Press, New York, s:45-135.
- [11] Bartlett M. S, Viola P. A, Sejnowski T. J, Golomb B. A, Larsen J, Hager J. C, Ekman P, 1996. Classifying Facial Action, Advances in Neural Information Processing Systems 8, s: 823-829.
- [12] Bayrakdar S, Akgün D, 2016. Yüz İfadelerinin Otomatik Analizi Üzerine Bir Literatür Çalışması SAÜ Fen Bil Der 20(2): 383-398.
- [13] Yacoob Y, Davis LS, 1996. Recognizing human facial expressions from long image sequences using optical flow. IEEE Transactions on Pattern Analysis and Machine Intelligence, 18(6): 636-642.
- [14] Tsapatsoulis N, Leonidou M, Kollias S, 1998. Facial Expression Recognition Using HMM with Observation Dependent Transition Matrix, IEEE Second Workshop on Multimedia Signal Processing, Redondo Beach,

- [15] Zhang Z, 1999. Feature-based Facial Expression Recognition: Sensitivity Analysis and Experiments with A Multi-layer Perceptron, *International Journal of Pattern Recognition and Artificial Interlligence*, 13(6): 893-911.
- [16] Cohen I, Garg A, Huang TS, 2000. Emotion recognition from facial expressions using multilevel HMM. *Neural Information Processing Systems (NIPS)*.
- [17] Gokturk S. B, Bouguet J. Y, Tomasi C, Girod B, 2002. Model-based Face Tracking for View In Dependent Facial Expression Recognition, *Proceedings of the Fifth IEEE International Conference on Automatic Face and Gesture Recognition*.
- [18] Silva LCD, Hui SC, 2003. Real-time facial feature extraction and emotion recognition. *Fourth Pacific Rim Conference on Multimedia, Information, Communications and Signal Processing, 2003 and the Fourth Pacific Rim Conference on Multimedia. Proceedings of the 2003 Joint 3: 1310-1314.*
- [19] Feng X, Pietikainen M, Hadid A, 2005. Facial expression recognition based on local binary patterns and linear programming, *Pattern Recognition and Image Analysis*, 15(2): 546-548.
- [20] Lajevardi SM, Lech M, 2008. Facial expression recognition from image sequences using optimized feature selection, *23rd International Conference Image and Vision Computing (IVCNZ)*, 26-28 Nov. 2008, New Zealand, s: 1-6.
- [21] Martins P, Sampaio J, Batista J, 2008. Facial expression recognition using active appearance models, *International conference on computer vision theory and applications (VISAPP)*, 22-25 Jan. 2008, Funchal, s: 123-129.
- [22] Song M, Tao D, Liu Z, Li X, Zhou M, 2010. Image ratio features for facial expression recognition application, *IEEE Transactions on Systems, Man and Cybernetics-Part B: Cybernetics*, 40(3): 779-788.
- [23] Oliveira L, Mansano M, Koerich A, Alceu de Souza Britto J, 2011. 2D principal component analysis for face and facial-expression recognition”, *Computing in Science & Engineering*, 13(3) 9-13.
- [24] Farahani FS, Sheikhan M, Farrokhi A, 2013. A fuzzy approach for facial emotion recognition, *13th Iranian Conference on Fuzzy Systems (IFSC)*, 27-29 Aug. 2013, Qazvin, s: 1-4.
- [25] <https://tipvefizik.wordpress.com/2013/02/22/336/> (Erişim Tarihi: 23.02.2021)
- [26] Edizer E, 2006. Sayısal Görüntü İşleme Yöntemi ile Tane Boyut Dağılımı Analizi. Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- [27] Yılmaz A, 2007. Kamera Kullanılarak Görüntü İşleme Yoluyla Gerçek Zamanlı Güvenlik Uygulaması. Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.

- [28] https://tr.wikipedia.org/wiki/G%C3%B6r%C3%BCnt%C3%BC_E%C5%9Fikleme (Erişim Tarihi: 13.07.2021)
- [29] Stasiek J, Stasiek A, Jewartowski M, Collins M W, 2006. Liquid Crystal Thermography and True-colour Digital Image Processing. Optics & Laser Technology, 38(4-6): 243-256.
- [30] Osmanoğlu U Ö, Mutlu F, Gürsoy H, Şanlısoy S, 2016. Görüntü İşleme ve Analizinin Tıpta Kullanımı ve Bir Uygulama. Osmangazi Tıp Dergisi, 41(1): 6-16.
- [31] Weeks A R, 1996. Fundamentals of Electronic Image Processing. SPIE Optical Engineering Press.
- [32] <https://www.geeksforgeeks.org/difference-between-pandas-vs-numpy/> (Erişim Tarihi: 13.07.2021)
- [33] Çalışan, M., & Türkoğlu, İ. 2013. Improvement of Thermal Camera Images Termal Kamera Görüntülerinin İyileştirilmesi. 7th International Advanced Technologies Symposium 30 ekim-1 kasım 2013, İstanbul.
- [34] Pınar Z, Gülağz F K, Altuncu M A, Şahin S, 2020. Denim Kumaşlarda Görüntü İşleme İle Hata Tespiti. Bitlis Eren Üniversitesi, Fen Bilimleri Dergisi, 9(4): 1609-1620.
- [35] Güvenoğlu E, Bağırhan M, 2019. Shearlet Dönüşümü ve Görüntü İşleme Teknikleri Kullanılarak Kot Kumaşlar Üzerinde Gerçek Zamanlı Hata Tespiti. El-Cezeri Journal of Science and Engineering, 6(3): 491-502.
- [36] Esmeray F, 2014. Açık Kaynak Kodlu Görüntü İşleme Uygulamaları. Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- [37] Al-Karawi M K, 2012. İkili Görüntü Kullanarak İmza Steganografi Modellerinin Geliştirilmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara.
- [38] <https://techterms.com/definition/pixel> (Erişim Tarihi: 22.02.2021)
- [39] <https://www.computerhope.com/jargon/p/pixel.htm> (Erişim Tarihi: 22.02.2021)
- [40] Yılmaz A, 2007. Kamera Kullanarak Görüntü İşleme Yoluyla Gerçek Zamanlı Güvenlik Uygulaması. Yüksek Lisans Tezi, Haliç Üniversitesi Fen bilimleri Enstitüsü, İstanbul.
- [41] Edizer E, 2006. Sayısal Görüntü İşleme Yöntemi İle Tane Boyut Dağılımı Analizi. Yüksek Lisans Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- [42] <https://www.webopedia.com/definitions/voxel/> (Erişim Tarihi : 22.02.2021)
- [43] Yalman Y, 2010. Sayısal Görüntüler için Histogram Temelli ve Gizleme Yöntemi ve Uygulama Yazılımı, Doktora Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- [44] <https://www.javatpoint.com/dip-histograms> (Erişim Tarihi : 23.02.2021)
- [45] Sabancı K, Aydın C, 2014. Görüntü İşleme Tabanlı Hassas İlaçlama Robotu. Journal of Agricultural Sciences, 20(4): 406-414

- [46] Kısa M, 2019. Grafik Tasarım ve Baskı Ortamında Kullanılan Görsellerin RGB Renk Uzayından CMYK Renk Uzayına Dönüşümü Esnasında Oluşan Renk ve Ton Kayıplarının Önlenmesi. *Humanities Sciences*, 14(2): 25-31.
- [47] Bayram R, 2019. Metal Sektörü için Görüntü İşleme Tabanlı Bir Kusurlu Ürün Tespit Sistemi, Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi, Bursa.
- [48] <https://www.sciencedirect.com/topics/engineering/binary-image> (Erişim Tarihi: 23.02.2021)
- [49] <https://www.sciencedirect.com/topics/engineering/grayscale-image> (Erişim Tarihi: 23.02.2021)
- [50] <https://tr.wikipedia.org/wiki/OpenCV> (Erişim Tarihi: 13.07.2021)
- [51] Bezryadin S, Bourov P, Ilinih D, 2007. Brightness Calculation in Digital Image Processing. 1st International Symposium on Technologies for Digital Photo Fulfillment, January 1, 2007, San Francisco, s: 10-15(6).
- [52] https://www.tutorialspoint.com/dip/brightness_and_contrast.htm (Erişim Tarihi: 26.02.2021)
- [53] <https://datacarpentry.org/image-processing/07-thresholding/#:~:text=Thresholding%20is%20a%20type%20of,is%20simply%20black%20and%20white> (Erişim Tarihi: 26.02.2021)
- [54] <https://www.geeksforgeeks.org/negative-of-an-image-in-matlab/> (Erişim Tarihi: 26.02.2021)
- [55] Değirmenci A, Çankaya İ, Demirci R, 2018. Gradyan Anahtarlama Gauss Görüntü Filtresi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6: 196-215.
- [56] <https://www.javatpoint.com/dip-concept-of-edge-detection> (Erişim Tarihi: 26.02.2021)
- [57] Vijayarani S, Vinupriya M, 2013. Performance Analysis of Canny and Sobel Edge Detection Algorithms in Image Mining. *International Journal of Innovative Research in Computer and Communication Engineering*.
- [58] <http://fourier.eng.hmc.edu/e161/lectures/gradient/node7.html> (Erişim Tarihi: 26.02.2021)
- [59] https://www.tutorialspoint.com/dip/laplacian_operator.htm (Erişim Tarihi: 26.02.2021)
- [60] Güvenç U, Elmas Ç, Demirci R, 2008. Renkli Görüntülerin Otomatik Ayırıştırılması. *Politeknik Dergisi*, 11(1): 9-12.
- [61] Ketenci S, 2011. Otomatik Tohumlandırma Bölge Büyütme Metoduyla Renkli Görüntülerde Bölge ve Kenar Tespiti, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon.
- [62] Maraşlı F, Öztürk S, 2018. Görüntü İyileştirme ve Görüntü Onarma Teknikleri ile Yapılmış

- Uygulamalar. 2. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi, 5 - 08 Temmuz 2018, Nevşehir, s:700-708.
- [63] Aslantaş V, Bendeş E, Kurban R, Toprak A N, 2011. Çoklu Algılayıcılardan Alınan Görüntülerde Eşleştirme Yöntemlerinin Karşılaştırılması. Elektrik-Elektronik ve Bilgisayar Sempozyumu Ekim 2011, s:110-114.
- [64] Dhawan S, 2011. A review of image compression and comparison of its algorithms. International Journal of electronics & Communication Technology, 2(1): 22-26.
- [65] Aytekin A, Yalçinkaya B, Dijital Görüntü İşleme Sistemi Kullanarak Bartın Orman Fakültesi Binasının ve Yerleşke Girişinin Düzenlenmesi. Bartın Orman Fakültesi Dergisi, 7(8): 37-48.
- [66] Resul D A Ş, Polat B, Tuna G. 2019. Derin Öğrenme ile Resim ve Videolarda Nesnelerin Tanınması ve Takibi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 31(2): 571-581.
- [67] Altunkurt Ö, Kahriman M, 2011. Gerçek Zamanlı Olarak, Anfis İle Renk Tabanlı Nesne Tespit Ve Motorlu Sistem İle Takip Edilmesi. Teknik Bilimler Dergisi, 1(1): 1-5.
- [68] Balaji, S R, Karthikeyan S, January 2017. A Survey on Moving Object Tracking Using Image Processing. In 2017 11th international conference on intelligent systems and control (ISCO), s:469-474.
- [69] Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Duchesnay E, 2011. Scikit-learn: Machine Learning in Python. The Journal of Machine Learning Research, 12: 2825-2830.
- [70] <https://www.python.org/doc/essays/blurp/> (Erişim Tarihi: 05.03.2021)
- [71] <https://datascientest.com/python-tout-savoir> (Erişim Tarihi: 05.03.2021)
- [72] <https://numpy.org/doc/stable/user/whatisnumpy.html> (Erişim Tarihi: 05.03.2021)
- [73] <https://www.javatpoint.com/pandas-vs-numpy> (Erişim Tarihi: 05.03.2021)
- [74] Ayvaz U, Gürüler H, 2017. Bilgisayar Kullanıcılarına Yönelik Duygusal İfade Tespiti. Bilişim Teknolojileri Dergisi, 10 (2): 231-239.
- [75] Viola P A, Jones M J, 2004. Robust Real-Time Face Detection, Int J Comput Vision, 57(2): 137-154.
- [76] Chen D, Ren S, Wei Y, Cao X, Sun J, 2014. Joint Cascade Face Detection and Alignment, European Conference on Computer Vision (ECCV), s:109-122
- [77] Priadana A, Habibi M. March 2019. Face Detection Using Haar Cascades to Filter Selfie Face Image on Instagram. In 2019 International Conference of Artificial Intelligence and Information Technology (ICAIIIT) s: 6-9.

- [78] Wilson P I, Fernandez J, 2006. Facial Feature Detection Using Haar Classifiers. Journal of Computing Sciences in Colleges, 21(4): 127-133.
- [79] Viola P, Jones M, 2001. Rapid Object Detection Using Boosted Cascade of Simple Features. 8-14 December 2001. IEEE Conference on Computer Vision and Pattern Recognition,
- [80] <http://yapayzekalabs.blogspot.com/2018/10/dlib-python-windows-installation.html> (Eriřim Tarihi: 07.03.2021)
- [81] <https://teknoloji.org/python-ile-yuz-tespiti-nasil-yapilir-python-kutuphanesi/> (Eriřim Tarihi: 07.03.2021)
- [82] Karamanlı E, 2019. Makine Öğrenmesi Algoritmaları Kullanarak, Metin Madencilięi ve Duygu Analizi ile Müřteri Deneyiminin Geliřtirilmesi, Yüksek Lisans Tezi, İstanbul Üniversitesi, İstanbul.
- [83] Louppe G, Varoquaux G, 2013. Scikit-Learn: Machine Learning in the Python ecosystem. NIPS 2013 Workshop on Machine Learning Open Source Software.
- [84] https://scikit-learn.org/stable/getting_started.html (Eriřim Tarihi: 08.03.2021)
- [85] https://scikit-learn.org/stable/modules/cross_validation.html (Eriřim Tarihi: 08.03.2021)
- [86] <https://www.ibm.com/cloud/learn/machine-learning> (Eriřim Tarihi: 08.03.2021)
- [87] Mumbuçoęlu M ř, 2019. Classification of Microarray Gene Expression Cancer Data By Using Artificial İntelligence Methods, M.Sc.Thesis, Hasan Kalyoncu University, Gaziantep.
- [88] Ibrahim OA, 2019. Sentiment Analysis Using Machine Learning, M.Sc.Thesis, Gaziantep Üniversitesi, Gaziantep.
- [89] <https://developer.ibm.com/articles/cc-unsupervised-learning-data-classification/> (Eriřim Tarihi: 09.03.2021)
- [90] Tařova O, 2011. Yapay Sinir Ağları ile Yüz Tanıma, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, İzmir.
- [91] Budak H, Erpolat S, 2012. Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karřılařtırılması. AJIT-e: Biliřim Teknolojileri Online Dergisi, 3(9): 23-30.
- [92] Verim V, 2005. Görüntü İřleme Yöntemleri ile Doku Sınırlarının Belirlenmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [93] Süer K, 2019. Yapay Zeka ile Meme Kanseri Lenf Nodu Analizi, Yüksek Lisans Tezi, Beykent Üniversitesi, İstanbul.
- [94] Gupta N, 2013. Artificial Neural Network. Network and Complex Systems, 3(1): 24-28.

- [95] Tutumlu H, 2011. Yapay Zekâ Yöntemleri ile El Damar Deseni Tanıma, Yüksek Lisans Tezi, Selçuk Üniversitesi, Konya.
- [96] Altun H, Eminoğlu U, Tezekici B S, 2010. MLP Yapay Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatiksel Değişim Gösteren Giriş Verilerine Bağımlılığı. EÜFBED - Fen Bilimleri Enstitüsü Dergisi, 3(2): 207-2019.
- [97] Çelik E, 2011. Görüntü İşlemeye Dayalı Avuç İzinin Yapay Sinir Ağı ile Tanınması, Yüksek Lisans Tezi, Marmara Üniversitesi, İstanbul.
- [98] <https://searchdatamanagement.techtarget.com/definition/TensorFlow> (Erişim Tarihi: 15.03.2021)
- [99] <https://www.tensorflow.org/> (Erişim Tarihi: 15.03.2021)
- [100] <https://opensource.com/article/17/11/intro-tensorflow> (Erişim Tarihi: 16.03.2021)
- [101] <https://keras.io/> (Erişim Tarihi: 16.03.2021)
- [102] <https://en.wikipedia.org/wiki/Keras#Features> (Erişim Tarihi: 16.03.2021)
- [103] <https://keras.io/api/callbacks/> (Erişim Tarihi: 16.03.2021)
- [104] https://keras.io/api/callbacks/csv_logger/ (Erişim Tarihi: 16.03.2021)
- [105] https://keras.io/api/callbacks/model_checkpoint/ (Erişim Tarihi: 16.03.2021)
- [106] https://keras.io/api/callbacks/early_stopping/ (Erişim Tarihi: 16.03.2021)
- [107] https://keras.io/api/callbacks/reduce_lr_on_plateau/ (Erişim Tarihi: 16.03.2021)
- [108] https://www.tutorialspoint.com/keras/keras_layers.htm (Erişim Tarihi: 17.03.2021)
- [109] <https://keras.io/api/layers/> (Erişim Tarihi: 17.03.2021)
- [110] Sufiyan Abdul-Karim N-Yo, 2018. Development Of A Real-Time Face Recognition, System Using Deep Learning Techiques, M.Sc.Thesis, University of Gaziantep, Gaziantep.
- [111] <https://www.upgrad.com/blog/basic-cnn-architecture/> (Erişim Tarihi: 07.04.2021)
- [112] Özkan İ N İ K, Ülker E, 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3): 85-104.
- [113] <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks> (Erişim Tarihi: 07.04.2021)
- [114] <https://www.geeksforgeeks.org/cnn-introduction-to-padding/> (Erişim Tarihi: 08.04.2021)
- [115] Arıç E, Turan M, 2020. Video Duygu Analizi. Avrupa Bilim ve Teknoloji Dergisi, Ejosat Özel Sayı 2020 (HORA) , s:59-67.
- [116] <https://towardsdatascience.com/deep-learning-for-computer-vision-c4e5f191c522> (Erişim Tarihi: 09.04.2021)
- [117] Kaya H, Cavusoglu A, Cakmak H B, Sen B, Delen D, 2016. Görüntü Bölütleme ve Görüntü Benzetimi Yöntemleri Yardımı ile Hastalığın Teşhis ve Tedavi Sonrası Süreçlerinin

- Desteklenmesi: Keratokonus örneği. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 31(3): 737-747
- [118] <https://www.analyticsvidhya.com/blog/2019/10/detailed-guide-powerful-sift-technique-image-matching-python/> (Erişim Tarihi: 09.04.2021)
- [119] De la Torre F, Cohn J F, 2011, Facial Expression Analysis. Visual Analysis of Humans, s:377-409.
- [120] Yakıt O, Özkan Y, 2017. Kurumsal Kaynak Planlama Sistemlerinde Yapay Sinir Ağlarının Değerlendirilmesi Yaklaşımı. Siyaset Ekonomi ve Yönetim Araştırmaları Dergisi, 5(2): 287-296.
- [121] <http://apelasyon.com/Yazi/927-tarimda-yapay-sinir-ag-uygulamalari> (Erişim Tarihi: 11.04.2021)
- [122] <https://towardsdatascience.com/deep-learning-for-computer-vision-c4e5f191c522> (Erişim Tarihi: 11.04.2021)
- [123] <https://www.kaggle.com/c/challenges-in-representation-learning-facial-expression-recognition-challenge/data> (Erişim Tarihi: 08.04.2021)
- [124] <https://keras.io/api/optimizers/adam/> (Erişim Tarihi: 08.04.2021)
- [125] <https://machinelearningmastery.com/softmax-activation-function-with-python/> (Erişim Tarihi: 09.04.2021)
- [126] <https://www.upgrad.com/blog/basic-cnn-architecture/> (Erişim Tarihi: 09.04.2021)
- [127] <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks> (Erişim Tarihi: 09.04.2021)
- [128] <https://muhendistan.com/elektromanyetik-radyasyon-nedir/> (Erişim Tarihi: 23.07.2021)
- [129] <https://medium.com/@sidathasiri/building-a-convolutional-neural-network-for-image-classification-with-tensorflow-f1f2f56bd83b> (Erişim Tarihi: 23.07.2021)
- [130] <https://www.kaggle.com/msambare/fer2013> (Erişim Tarihi: 25.08.2021)
- [131] https://en.wikipedia.org/wiki/Stochastic_gradient_descent (Erişim Tarihi: 02.09.2021)
- [132] Chen X, Cheng W, 2015. Facial expression recognition based on edge detection, International Journal of Computer Science & Engineering Survey (IJCSES), 6(2): 1- 9.
- [133] Neoh SC, Zhang L, Mistry K, Hossain MA, Lim CP, Nauman Aslam PK, 2015. Intelligent facial emotion recognition using a layered encoding cascade optimization model, Elsevier Applied Soft Computing, 34: 72-93.
- [134] https://docs.opencv.org/3.4/db/d28/tutorial_cascade_classifier.html (Erişim Tarihi 07.09.2021)

[135] https://en.wikipedia.org/wiki/Batch_normalization (Eriřim Tarihi: 07.09.2021)



ÖZGEÇMİŞ

İdil KOÇ

