

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



HASTANE ORTAMINDA ENFEKSİYON KONTROLÜ İÇİN  
AKILLI İZLEME VE TESPİT SİSTEMLERİ

YÜKSEK LİSANS TEZİ

Rafet DUR

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Elektrik ve Elektronik Mühendisliği (Tezli) Yüksek Lisans Programı

MAYIS 2025  
İSTANBUL

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



HASTANE ORTAMINDA ENFEKSİYON KONTROLÜ İÇİN  
AKILLI İZLEME VE TESPİT SİSTEMLERİ

YÜKSEK LİSANS TEZİ

Rafet DUR  
(241280004)

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Elektrik ve Elektronik Mühendisliği (Tezli) Yüksek Lisans Programı

Tez Danışmanı: Prof. Dr. Feriha Erfan KUYUMCU

İstanbul 2025



T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Jüri Tez Onay Formu

28.05.2025

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ

Bu çalışma 28.06.2025 tarihinde aşağıdaki jüri tarafından Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Elektrik ve Elektronik Mühendisliği (Tezli Yüksek Lisans) Programı Yüksek Lisans Tezi olarak kabul edilmiştir.

TEZ JÜRİSİ

**Prof. Dr. Feriha Erfan KUYUMCU**

Danışman

İstanbul Gedik Üniversitesi

**Dr. Öğr. Üyesi Mehmet KARA**

Üye (İmza)

Kocaeli Sağlık ve Teknoloji Üniversitesi

**Dr. Öğr. Üyesi Burcu BEKTAŞ**

**GÜNEŞ**

Üye (İmza)

İstanbul Gedik Üniversitesi

## YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Hastane Ortamında Enfeksiyon Kontrolü İçin Akıllı İzleme ve Tespit Sistemleri” adlı bu çalışmanın, tezin proje safhasından sonuçlanmasına kadar olan bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (28/06/2025)

Rafet DUR

## ÖNSÖZ

Başta, yüksek lisans eğitimimde ve akademik hayatımda desteğini, yardımlarını, bilgisini esirgemeyerek her daim yanımda olan ve bu çalışmanın ortaya çıkmasında büyük emeği geçen danışmanım Prof. Dr. Feriha Erfan KUYUMCU'ya ve tüm çalışmalarım sürecinde yanımda olan, bilgi ve tecrübesini paylaşan değerli hocam Doç. Dr. Kasım TAKİM'a en içten teşekkürlerimi sunarım.

Mayıs 2025

Rafet DUR

---

## İÇİNDEKİLER

	Sayfa No.
<b>ÖNSÖZ</b> .....	<b>iv</b>
<b>İÇİNDEKİLER</b> .....	<b>v</b>
<b>KISALTMALAR</b> .....	<b>vii</b>
<b>ÇİZELGE LİSTESİ</b> .....	<b>viii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>ix</b>
<b>ÖZET</b> .....	<b>x</b>
<b>ABSTRACT</b> .....	<b>xi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Tezin Amacı .....	2
1.2 Araştırmada Kullanılan Tez ve Makaleler .....	3
<b>2. GÖRÜNTÜ İŞLEME VE YÜZ TARAMA</b> .....	<b>14</b>
2.1 Sayısal Görüntü İşleme .....	15
2.2 Piksel Üzerinde Yapılan İşlemler .....	16
2.2.1 Analog görüntünün sayısallaştırılması .....	17
2.2.2 Görüntü Örneklemesi .....	17
2.2.3 Görüntü nicemleme .....	18
2.2.4 Gri görüntü .....	18
2.2.5 Renkli görüntü .....	19
2.3 Bellek Alanı.....	21
2.3.1 Sayısal görüntünün kapladığı bellek alanı.....	21
2.3.2 Çözünürlük .....	22
2.3.3 Alan hassaslığı (piksel çözünürlüğü).....	22
2.3.4 Parlaklık hassaslığı .....	23
2.3.5 Uygun çözünürlük değerlerinin belirlenmesi .....	23
2.3.6 Yüz tarama yöntemi .....	24
<b>3. METODOLOJİ, SONUÇ VE ÖNERİLER</b> .....	<b>30</b>
3.1 Sistemsel Metodoloji.....	30
3.1.1 Veri toplama ve ön işleme .....	30

3.1.2 Model geliştirme ve eğitimi.....	32
3.1.3 Donanım performans değerlendirmesi .....	32
3.1.4 Model ve donanım optimizasyonu .....	32
3.1.5 Hız-doğruluk-maliyet dengesi .....	33
3.1.6 Gerçek zamanlı uygulamada test ve değerlendirme .....	33
3.1.7 Uygulama ve entegrasyon .....	33
3.1.8 Eğitim süreci ve kayıp fonksiyon analizi .....	33
3.1.9 Model performans analizi ve değerlendirme .....	34
3.1.10 Hiperparametre ayarlamaları ve eğitim stratejisi.....	36
3.2 Yazılım Metodolojisi.....	37
3.2.1 Resnet .....	37
3.3 Sonuçlar.....	40
3.4 Sistem Gereksinimleri .....	43
3.5 Hız Testi .....	46
3.6 Eğitim Verisi Öğrenme Grafiği .....	47
3.7 Doğruluk Testi Grafiği .....	52
3.8 Gelecekte Yapılması Öngörülen Geliştirmeler .....	58
<b>KAYNAKÇA .....</b>	<b>61</b>
<b>ÖZGEÇMİŞ.....</b>	<b>64</b>

## KISALTMALAR

<b>GPU</b>	: Grafik İşleme Birimi (Graphics Processing Unit)
<b>CPU</b>	: Merkezi İşlem Birimi (Central Processing Unit)
<b>FRP</b>	: Saniye Başına Kare (FPS Frames Per Second)
<b>DL</b>	: Derin Öğrenme (Deep Learning)
<b>AI, YZ</b>	: Artificial intelligence (Yapay Zeka)
<b>IEEE</b>	: The Institute of Electrical and Electronics Engineers
<b>FRGC</b>	: Face Recognition Grand Challenge
<b>RGB</b>	: Kırmızı, Yeşil, Mavi (Red, Green, Blue)
<b>DL</b>	: Derin Öğrenme (Deep Learning)
<b>ResNet</b>	: Kalan Ağlar (Residual Networks)
<b>VGG</b>	: Görsel Geometri Grubu (Visual Geometry Group)
<b>R-CNN</b>	: Bölge Tabanlı Evrişimsel Sinir Ağı (Region-Based Convolutional Neural Network)
<b>COCO</b>	: Bağlamdaki Ortak Nesneler (Common Objects in Context)
<b>DNN</b>	: Derin Sinir Ağı (Deep Neural Network)
<b>MM</b>	: Matematiksel Morfoloji

## ÇİZELGE LİSTESİ

	<b>Sayfa No.</b>
Çizelge 3.1: Farklı Ağ Mimarilerinin ImageNet (ILSVRC) Üzerindeki Top-1 ve Top-5 Hata Oranları (%) .....	36
Çizelge 3.2: Plain ve Resnet (%).....	40
Çizelge 3.3: Resnet Method Hata Verileri (%) .....	42
Çizelge 3.4: Freme per sechond (Saniye Başına Düşen Görsel).....	46



## ŞEKİL LİSTESİ

	<b>Sayfa No.</b>
Şekil 2.1: Sayısal Görüntü İşleme .....	15
Şekil 2.2: Piksel Değerleri .....	17
Şekil 2.3: Analog ve Dijital Görüntü .....	17
Şekil 2.4: Gri Görüntü .....	19
Şekil 2.5: Üç Renk .....	20
Şekil 2.6: Gri Ton Renklendirme .....	21
Şekil 2.7: Hassasiyetlik .....	23
Şekil 2.8: Yüz Tarama Bilgisi .....	25
Şekil 2.9: Yüz Maskesi Tarama Bilgisi .....	26
Şekil 2.10: Yüz Tarama Sistemi .....	28
Şekil 2.11: Pi Grafiği .....	28
Şekil 2.12: Pirinç Tanesi Modeli .....	29
Şekil 3.1: Orijinal Görüntü için Derin Artık Öğrenme .....	38
Şekil 3.2: Artık Bloklar .....	39
Şekil 3.3: Plain ve Resnet Grafik .....	41
Şekil 3.4: Yıllara göre Sınıflandırma Hataları .....	42
Şekil 3.5: Sistemin Akış Diyagramı .....	44
Şekil 3.6: Eğitim Doğruluğu Test Grafiği .....	48
Şekil 3.7: Eğitim Değerlerine Göre Doğruluk Oranları .....	49
Şekil 3.8: Doğruluk Test Data Doğrulama Başarı Oranları .....	54
Şekil 3.9: Test Data Doğrulama Başarı Oranları .....	55

## HASTANE ORTAMINDA ENFEKSİYON KONTROLÜ İÇİN AKILLI İZLEME VE TESPİT SİSTEMLERİ

### ÖZET

Bu çalışma, hastane ortamında enfeksiyon kontrolüne yönelik derin öğrenme tabanlı bir maske tespit sisteminin CPU (Central Process Unit) ve GPU (Graphics Process Unit) üzerindeki performans farklılıklarını incelemektedir. Derin öğrenme modelleri arasında yer alan ResNet varyantları, maske tespiti amacıyla eğitilmiş olup, ameliyathane gibi yüksek doğruluğun kritik olduğu alanlar ile bekleme salonu gibi daha yoğun, ancak düşük hassasiyet gerektiren alanlarda uygulanabilirlikleri değerlendirilmektedir.

Bu tez çalışmasında, CPU ve GPU donanımlarında maske tespiti modellerinin performans analizleri gerçekleştirilmiş olup; kare hızı (FPS), doğruluk oranları ve maliyet gibi metrikler üzerinden, her iki donanımın farklı hastane senaryolarındaki uygunluğu incelenmektedir. Ameliyathaneler gibi yüksek doğruluğun zorunlu olduğu ortamlarda GPU'nun sağladığı hız ve doğruluk avantajları öne çıkarken, kalabalık fakat düşük hassasiyet gerektiren alanlarda CPU'nun maliyet-etkin çözümler sunduğu gözlemlenmektedir.

Bu çalışma, hastanelerdeki farklı kullanım senaryoları için hız, doğruluk ve maliyet dengesini gözeterek en uygun model ve donanım yapılandırmalarını belirlemeyi amaçlamaktadır. Gerçekleştirilen kapsamlı analizler ve önerilen model optimizasyonları, maske tespiti sistemlerinin pratik uygulamalarda verimli ve doğru bir biçimde dağıtılması için literatüre özgün bir katkı sağlaması beklenmektedir.

**Anahtar Kelimeler:** *Enfeksiyon Kontrolü, Derin Öğrenme, Maske Tespiti, ResNet, Model Optimizasyonu, Kare Hızı (FPS), Doğruluk Oranı, Maliyet-Etkinlik*

# SMART MONITORING AND DETECTION SYSTEMS FOR INFECTION CONTROL IN HOSPITAL ENVIRONMENT

## ABSTRACT

This study examines the performance differences on a deep learning-based mask detection system CPU and GPU for control in hospital environments. ResNet details among deep learning models have been classified for mask detection purposes, and their applicability in high-temperature critical areas such as workrooms and more dense but low-range areas such as waiting rooms has been evaluated.

In the study, performance analyzes of masking models in CPU and GPU hardware have been performed; There are options for both hardware in different hospital scenarios through metrics such as frame rate (Frame Per Second - FPS), accuracy rates and cost. While the speed and accuracy ranges of GPU distribution in places where high temperatures are mandatory such as operating rooms stand out, cost-effective solutions of CPU have been observed in crowded but low-range areas.

This study provides the determination of suitable model and hardware features by considering speed, accuracy and cost for different usage scenarios in hospitals. The comprehensive analyses and suggested model changes provide an original contribution to the literature for the efficient and accurate distribution of mask detection results in practical applications.

**Keywords:** *Infection Control, Deep Learning, Mask Detection, ResNet, Model Optimization, Frame Rate (FPS), Accuracy Rate, Cost Effectiveness*

## 1. GİRİŞ

Son yıllarda bilgisayar görüşü ve yapay zekâ teknolojilerindeki gelişmeler, sağlık sektöründe farklı uygulamaların geliştirilmesine olanak tanımaktadır. Enfeksiyon kontrolünün önemli olduğu hastane ortamlarında, maskelerin doğru ve düzenli şekilde kullanılması büyük bir gereklilik haline gelmektedir. Özellikle operasyonel alanlar ve hastane bekleme salonları gibi yoğun bölgelerde maskenin doğru kullanımının denetlenmesi, enfeksiyonun yayılma riskini azaltmada önemli bir rol oynamaktadır. Bu nedenle, maskelerin doğru şekilde takıldığını belirlemek amacıyla gerçek zamanlı çalışan otomatik maske tespiti sistemlerinin geliştirilmesi, halk sağlığını korumak ve hastane içindeki bulaşma riskini azaltmak adına kritik bir ihtiyaç haline gelmiştir.

Bu tez çalışmasında, yüz maskesi tespitinde kullanılmak üzere derin öğrenme tabanlı bir sistemin geliştirilmesi ve bu sistemin farklı donanım platformlarında (CPU ve GPU) nasıl performans gösterdiğinin detaylı olarak incelenmesi amaçlanmaktadır. Bu tür bir sistem, yüz özelliklerini tanıyarak maskenin varlığını ve doğru kullanımını tespit edebilir, bu da hastanelerde maske takibi için önemli bir araç sunar. Çalışmada kullanılan model olarak ResNet ailesine ait varyantlar tercih edilmektedir, çünkü bu modeller özellikle nesne tanıma ve yüz tanıma gibi görsel analizlerde yüksek başarı oranlarına sahiptir.

Maske tespiti uygulamaları, farklı kullanım senaryolarına göre değişiklik gösteren gereksinimlere sahiptir. Örneğin, ameliyathane gibi yüksek hassasiyet gerektiren alanlarda doğruluk ön planda iken, bekleme salonları gibi daha yoğun alanlarda hız öncelikli bir gereksinim olabilir. Bu durum, donanım seçimi ve model konfigürasyonlarının optimize edilmesini zorunlu kılmaktadır. CPU ve GPU üzerindeki performans karşılaştırmalarının yapılması, bu iki donanım arasında hız ve doğruluk açısından nasıl bir denge kurulabileceğini anlamak adına büyük önem taşır. CPU'lar genellikle düşük maliyetli ve erişilebilir donanımlar olsa da GPU'lar yoğun işlem gücü gerektiren uygulamalarda daha yüksek performans sağlayabilirler. Bu tezde, her iki donanımın kare hızı (FPS), doğruluk oranları ve maliyet açısından

karşılaştırmaları yapılarak, hastane ortamında kullanıma en uygun yapılandırmalar belirlenmeye çalışılacaktır.

Bu çalışmanın amacı, hastane gibi enfeksiyon kontrolünün kritik olduğu ortamlarda, derin öğrenme tabanlı maske tespiti sisteminin performansını optimize etmek ve kullanım gereksinimlerine göre en uygun model ve donanım yapılandırmalarını sunmaktır. Tez kapsamında, maske tespiti teknolojisinin hastanelerdeki uygulanabilirliği, hız ve doğruluk ihtiyaçlarına göre değerlendirilerek literatüre katkı sağlanması hedeflenmektedir. Çalışmanın sonuçları, benzer tespit sistemlerinin sağlık sektörü ve diğer toplu kullanım alanlarında kullanımını artırmak için rehberlik edici bir kaynak niteliğinde olacaktır.

### 1.1 Tezin Amacı

Bu tezin amacı, hastane gibi enfeksiyon kontrolünün kritik olduğu ortamlarda, yüz maskesi tespiti için derin öğrenme tabanlı bir sistemin geliştirilmesi ve bu sistemin CPU ve GPU gibi farklı donanım platformlarındaki performansını kapsamlı bir şekilde incelemektir. Özellikle gerçek zamanlı uygulamalarda maskenin doğru ve düzenli kullanılmasının sağlanması, enfeksiyon riskini azaltma açısından büyük önem taşımaktadır. Bu noktada, maske takılmadığını veya yanlış takıldığını doğru bir şekilde tespit eden bir sistem, enfeksiyon kontrolünde önemli bir araç sunmaktadır. Çalışmada, derin öğrenme tabanlı ResNet modellerinin bu görevde nasıl bir performans sergilediği analiz edilerek, hastane içi kullanım için en uygun konfigürasyonlar ortaya konacaktır.

Tezde aşağıda belirtilen konular üzerinde duruldu:

- a. **Derin Öğrenme Tabanlı Maske Tespit Sistemi:** Yüz maskesi tespiti için ResNet modellerinin eğitimi ve yüksek doğruluk sağlamak için optimize edilmesi.
- b. **Donanım Performans Analizi:** CPU ve GPU üzerindeki sistem performansları kare hızı (FPS), doğruluk ve maliyet açısından değerlendirildi.
- c. **Optimum Yapılandırmaların Belirlenmesi:** Farklı kullanım senaryolarına (ameliyathane, bekleme salonları vb.) en uygun model ve donanım yapılandırmalarının seçilmesi.

- d. **Hız-Doğruluk-Maliyet Dengesi:** Performans ile maliyet arasındaki dengeyi sağlayarak en uygun yapılandırmanın belirlenmesi.

Bu tez, yukarıda belirtilen amaçlar doğrultusunda, gerçek zamanlı maskeli yüz tespiti teknolojisinin hastane gibi kritik ortamlarda uygulanabilirliğini artırmayı ve kullanım gereksinimlerine göre en uygun model ve donanım konfigürasyonlarını belirlemeyi hedefledi. Çalışmanın sonuçları, sağlık sektörü başta olmak üzere, toplu kullanım alanlarında maskeli yüz tespiti için yönlendirici bir kaynak sağlayarak, enfeksiyon kontrolü ve halk sağlığı için önemli bir katkı sunmayı amaçladı.

## 1.2 Araştırmada Kullanılan Tez ve Makaleler

### [1] Numaralı Yayın Referansdır

H. Wang'ın 2019 yılında yazdığı "Deep Neural Networks for Visual Object Recognition" başlıklı doktora tezi, derin öğrenme teknikleri, özellikle derin sinir ağlarının (DNN'ler) görsel nesne tanıma görevindeki uygulamalarına odaklandı. Bu çalışma, özellikle konvolüsyonel sinir ağları (CNN'ler) ile görsel tanıma doğruluğunu artırmaya yönelik yöntemlerin geliştirilmesini amaçladı.

Tezde ele alınan temel konular şunlardır:

**Gelişmiş CNN Mimarileri:** Wang, nesne tanıma doğruluğunu artırmak için yeni CNN mimarilerinin geliştirilmesine odaklandı. Bu mimariler, görüntülerdeki nesnelere daha verimli bir şekilde tanıyabilen, iyileştirilmiş ağ yapıları önererek, görsel algılama görevini daha etkin hale getirdi.

**Eğitim Teknikleri ve Zorluklar:** Derin ağların eğitilmesi sırasında karşılaşılan büyük veri gereksinimi ve hesaplama yükü gibi zorluklar tartışıldı. Ayrıca, daha küçük veri setlerinde daha etkili eğitim sağlamak için transfer öğrenme gibi yöntemler ele alındı.

**Gerçek Dünya Uygulamaları:** Wang, araştırmasının temelini gerçek dünya uygulamalarına dayandırdı. Özellikle, otonom araçlar gibi güvenli yol navigasyonu için kritik öneme sahip nesne tanıma ve sağlık alanlarında tıbbi görüntüleme gibi uygulamalara yer verildi.

**Optimizasyon ve Verimlilik:** Wang'ın araştırması, DNN'lerin hesaplama verimliliğini artırmaya yönelik geliştirmelere odaklandı. Bu, ağ küçültme (pruning)

ve ağırlık kuantizasyonu gibi yöntemlerle ağın karmaşıklığını azaltarak daha hızlı ve verimli modeller geliştirmeyi hedefledi.

**Büyük Ölçekli Veri Setleri ve Performans:** Tez, büyük ölçekli veri setlerinin kullanımı, özellikle ImageNet gibi veri setlerinde modellerin eğitime ve bu modellerin genelleme kabiliyetlerine odaklandı.

**Nesne Tespiti ve Konumlandırma:** Wang, nesne sınıflandırmasının yanı sıra, nesne tespiti ve yerleştirme gibi daha karmaşık görevleri de ele aldı. Bu, sadece nesnelerin tanınmasını değil, aynı zamanda görüntülerdeki nesnelerin konumlarının tespit edilmesini de içerdi.

**Alana Katkılar:** Wang'ın araştırması, derin öğrenme ve bilgisayarla görme alanına önemli katkılar sunmakta olup, güvenlik, robotik, artırılmış gerçeklik gibi sektörlerdeki uygulamalar için pratik çıkarımlar yapıldı.

Bu tez, derin öğrenme modellerinin görsel nesne tanıma alanındaki gelişimini ileriye taşıyan yenilikçi yaklaşımlar sunarak, model optimizasyonu, büyük veri setleri ile eğitim ve gerçek dünya uygulamalarına dair önemli bilgiler sağladı.

## **[2] Numaralı Yayın Referansdır**

"Performance Analysis of CPU and GPU for Deep Learning Models in Real-Time Applications" başlıklı tez, derin öğrenme modellerinin farklı donanım platformlarında, özellikle merkezi işlem birimi (CPU) ve grafik işlem birimi (GPU) üzerinde performansını incelendi. Bu araştırma, yüksek hızda veri işleme ve düşük gecikme gereksinimleri olan gerçek zamanlı uygulamalar için son derece önemlidir.

### **Tezin Temel Konuları:**

**CPU ve GPU Performans Karşılaştırması:** Tez, derin öğrenme modellerinin CPU ve GPU üzerindeki performansını karşılaştırmaya odaklandı. Performans değerlendirmeleri, işlem süresi, bellek kullanımı ve enerji tüketimi gibi birçok metrikle yapılmıştır. GPU'lar, paralel işleme yetenekleri sayesinde özellikle işlem süresi açısından CPU'lara göre önemli avantajlar sağlamaktadır ve bu, yüksek veri akışı ve düşük gecikme gereksinimleri olan uygulamalarda oldukça kritiktir.

**Çoklu GPU Yapılandırmaları:** Tezde, birden fazla GPU'nun birlikte kullanıldığı sistemler incelendi. Bu, görevlerin birden çok GPU'ya dağıtılmasını sağlayarak eğitim ve tahmin sürelerini önemli ölçüde hızlandırdı. Çoklu GPU

yapılandırmaları, büyük veri setlerinde veya karmaşık model yapılarında özellikle etkili oldu. Bu yapılandırmalar, video işleme gibi gerçek zamanlı uygulamalarda düşük gecikme gereksinimlerinin karşılanmasına olanak tanıdı.

**Optimizasyon Teknikleri:** Verimli derin öğrenme modelleri için veri paralelliği, model paralelliği ve batch boyutu ayarlamaları gibi optimizasyon yöntemleri incelendi. Veri paralelliği, verilerin birden çok GPU'ya bölünmesini içerirken, model paralelliği modelin kendisinin dağıtılmasını sağlar. Batch boyutu optimizasyonu, bellek kullanımı ile işlem hızı arasında bir denge kurarak genel performansı artırır. Bu teknikler, derin öğrenme modellerinin verimliliğini artırmaya yönelik çözüm stratejileri sundu.

**Veri Hareketi ve Senkronizasyon Zorlukları:** Çoklu GPU yapılandırmalarında, cihazlar arasındaki veri hareketi ve hesaplamaların senkronizasyonu gecikmelere yol açabilir. Tez, bu gecikmeleri azaltmaya yönelik çözümler önermektedir. Özellikle, GPU'lar arasındaki iletişim protokollerinin iyileştirilmesi ve yüksek bant genişliğine sahip belleklerin kullanılması, gecikmeleri azaltmak için kritik öneme sahiptir. Bu iyileştirmeler, gerçek zamanlı sistemlerde daha hızlı ve daha doğru çıkarım yapılmasını sağladı.

**Gerçek Zamanlı Uygulamalardaki Kullanımı:** Tezde, gerçek zamanlı uygulamalar olan tıbbi görüntüleme, otonom sürüş ve endüstriyel otomasyon gibi alanlarda CPU ve GPU performansı karşılaştırıldı. Bu alanlar, yüksek doğrulukla büyük veri setlerinin hızlı bir şekilde işlenmesini gerektirdiği için oldukça önemlidir. Araştırma, bu uygulamalarda GPU'ların performans açısından CPU'lardan nasıl belirgin şekilde üstün olduğunu vurgulandı.

**Çerçeveler ve Araçlar:** TensorFlow, PyTorch ve Caffe gibi derin öğrenme çerçeveleri, CPU ve GPU sistemleri için optimizasyon açısından değerlendirildi. Bu araçlar, derin öğrenme modellerinin verimli bir şekilde çalışmasını sağlar ve tezde bu çerçevelerin GPU'ların paralel işleme gücünü nasıl kullandığına dair tartışmalar yer aldı.

**Sonuç:**

Sonuç olarak, bu tez, CPU'ların belirli hesaplamalar için hâlâ önemli olsa da GPU'ların özellikle çoklu GPU yapılandırmalarında derin öğrenme modellerinin eğitim ve çıkarım hızlarında CPU'lara göre önemli bir avantaj sağladığını ortaya

koydu. Verimli derin öğrenme modelleri için veri paralelliği, model paralelliği ve batch boyutu ayarlamaları gibi optimizasyon yöntemlerinin önemine vurgu yapıldı. Bu bulgular, gerçek zamanlı veri işleme gereksinimlerine sahip endüstriler için kritik öneme sahiptir, örneğin tıbbi görüntüleme (tanı amacıyla) ve otonom sistemler (araç yönlendirme ve karar verme).

### **[3] Numaralı Yayın Referansdır**

Bu araştırma, görüntü tanıma performansını iyileştirmek için çok ölçekli bir dikkat mekanizması içeren ResNet-50 modelinin geliştirilmiş bir versiyonunu sundu. Çalışma, ölçek değişikliklerine duyarlılık ve mekânsal yedeklilik gibi standart evrişimli ağlardaki sınırlamaları ele almaya odaklandı.

Ana katkılar şunlardır:

**Çok Ölçekli Dikkat Mekanizması:** Geliştirilmiş model, birden fazla ölçek boyunca farklı mekânsal ve kanal özelliklerine dinamik olarak ağırlık atayan dikkat modüllerini entegre ederek modelin ilgili özelliklere odaklanma yeteneğini arttırdı.

**Mimari Değişiklikleri:** ResNet-50 omurgasındaki ayarlamalar, değişen çözünürlüklere sahip görüntüleri etkili bir şekilde işlemek üzere tasarlanmış optimize edilmiş artık blokları ve dikkat katmanlarını içerir.

**Performans Değerlendirmesi:** ImageNet gibi veri kümeleri üzerinde yürütülen deneyler, geliştirilmiş ResNet-50'nin özellikle ayrıntılı özellik çıkarma gerektiren görevlerde orijinal modele kıyasla daha yüksek doğruluk ve daha hızlı yakınsama sağladığını gösterdi.

**Gerçek Dünya Uygulamaları:** Çalışma, hassas nesne tespitinin kritik olduğu tıbbi görüntüleme, otonom sürüş ve gözetim gibi alanlardaki potansiyel uygulamaları vurguladı.

Bu geliştirilmiş mimari, derin öğrenme modeli performansını arttırmada dikkat mekanizmalarının önemini sergileyerek, gelişmiş görüntü tanıma yetenekleri gerektiren görevler için değerli bir kaynak haline getirdi.

### **[4] Numaralı Yayın Referansdır**

Taylor ve Smith (2023) tarafından gerçekleştirilen bu kapsamlı sistematik inceleme, 2018–2023 yılları arasında yayımlanan çalışmaları esas alarak, hastane ve uzun süreli bakım tesislerinde sağlık hizmetiyle ilişkili enfeksiyonların (HAI)

kontrolü ve gözetiminde kullanılan dijital teknolojilerin etkinliğini değerlendirmektedir. PRISMA-ScR metodolojisi doğrultusunda yürütülen araştırma, dijital uygulamaların güncel sağlık sistemlerine entegrasyonuna yönelik çok boyutlu bir analiz sundu.

İncelemede ele alınan teknolojiler arasında makine öğrenimi algoritmaları, otomatik gözetim sistemleri ve elektronik sağlık kayıtlarının entegrasyonu yer almakta olup, bu sistemler geleneksel yöntemlerle karşılaştırmalı olarak analiz edilmiştir. Ayrıca, sağlık personeli, bilişim teknolojileri ve analitik yaklaşımlar arasındaki disiplinler arası entegrasyon değerlendirilerek bu yapının sunduğu katkılar ve karşılaşılan zorluklar ortaya konuldu.

Çalışma bulguları, makine öğrenimi algoritmalarının büyük ölçekli veri kümeleri ile uygulandığında enfeksiyon salgınlarını tahmin etme ve kalıpları belirleme açısından geleneksel yöntemlere kıyasla daha başarılı sonuçlar verdiğini gösterdi. Bununla birlikte, bu teknolojilerin sağlık sistemlerine entegrasyonu bazı önemli engelleri de beraberinde getirmektedir. Özellikle veri gizliliği, yüksek düzeyde teknik altyapı ihtiyacı ve sistemler arası uyum sorunları, dijital uygulamaların yaygın biçimde benimsenmesini sınırlayan başlıca faktörler olarak öne çıkarıldı.

Bu teknolojilerin etkin bir biçimde uygulanabilmesi için sağlık çalışanlarının gerekli dijital yetkinliklere sahip olması elzemdir. Dolayısıyla, kapsamlı eğitim programlarının geliştirilmesi ve dijital sistemlerin kullanımı konusunda rehberlik sağlayacak güncellenmiş düzenleyici çerçevelerin oluşturulması gereklidir. Ayrıca, dijital araçların enfeksiyon oranlarını düşürmede özellikle kaynak kısıtlı sağlık ortamlarında önemli bir potansiyel taşıdığı görülmektedir. Ancak bu potansiyelin etkili bir şekilde hayata geçirilebilmesi, disiplinler arası iş birliğinin sağlanması ve teknolojik entegrasyonun dikkatli bir şekilde planlanmasıyla mümkün olacaktır.

Sonuç olarak, dijital teknolojiler sağlık hizmetlerinde enfeksiyon kontrolünde dönüştürücü bir rol üstlenebilecek kapasiteye sahiptir. Bu dönüşüm, yalnızca enfeksiyonların daha hızlı ve doğru şekilde tespit edilmesini sağlamakla kalmayıp, aynı zamanda hasta güvenliğini artırmakta ve sağlık sistemlerinin sürdürülebilirliğine katkı sundu. Ancak bu süreçte, veri güvenliğinin sağlanması, kullanıcı eğitiminin

güçlendirilmesi ve yasal düzenlemelerin güncellenmesi temel gereklilikler arasında yer aldı.

#### **[5] Numaralı Yayın Referansdır**

J. B. Roerdink'in "Mathematical Morphology and Its Application to Image Processing" başlıklı doktora tezi, görüntü işleme alanında matematiksel morfolojinin (MM) temellerini kapsamlı bir şekilde ele almakta ve bu teorinin gerçek dünya uygulamalarına nasıl adapte edilebileceğini incelenmiştir. Roerdink, matematiksel morfoloji kavramlarını set teorisi ve matris yapıları üzerinden detaylandırmış ve görsel verilerdeki şekil ve yapıların çıkarılmasına yönelik önemli katkılarda bulunmuştur.

Tezde, matematiksel morfolojinin temel işlemleri olan dilatasyon ve erozyon gibi kavramlar açıklanmış, bu işlemler görsellerdeki nesnelerin sınırlarını genişletme ve daraltma işlemleri olarak tanımlandı. Ayrıca, açma ve kapama işlemleriyle birleşen bu iki temel işlem, görüntüdeki gürültülerin giderilmesi veya nesne sınırlarının netleştirilmesi gibi işlevler sağladı. Matematiksel morfolojinin teorik altyapısı, özellikle set teorisi ve matris teorisi üzerinden ele alınmış ve görüntülerin üzerinde yapılan işlemler, yapısal elementler kullanılarak daha derin bir matematiksel çerçeveye oturtuldu. Bu, konunun matematiksel temellerini anlamak için kritik bir öneme sahiptir.

Roerdink, matematiksel morfolojinin görsel veri analizi üzerindeki pratik uygulamalarını da incelemiş ve özellikle görüntü iyileştirme, kenar tespiti ve segmentasyon gibi temel işlemlerin matematiksel morfoloji ile nasıl optimize edilebileceği üzerine çalışmalar yapılmıştır. Tezde, daha ileri düzey morfolojik işlemler, özellikle morfolojik filtreler ve mesafe dönüşümleri gibi konular detaylandırılmış ve bu işlemler, görüntülerdeki belirli özellikleri vurgulamak, nesnelerin şekillerini tanımlamak ve analiz etmek için kullanılmıştır.

Tez, ayrıca matematiksel morfolojinin medikal görüntüleme, uydu görüntü işleme ve biyolojik görüntü analizi gibi çeşitli alanlarda nasıl uygulandığını göstermektedir. Roerdink'in çalışması, matematiksel morfolojinin görüntü işleme alanında son derece esnek ve güçlü bir araç olduğunu vurgulamıştır. Tez, yalnızca teorik bir bakış açısı sunmakla kalmayıp, aynı zamanda bu teorinin gerçek dünya problemlerinde nasıl uygulanabileceğini de göstermiştir. Günümüzde hala birçok ileri

düzye görüntü işleme tekniğinin temelini atan bu çalışma, özellikle şekil tabanlı analizlerle ilgili konularda önemli bir referans kaynağı oldu. [17]

### **[6] Numaralı Yayın Referansdır**

"Çok Ölçekli Dikkat Mekanizması Tabanlı Geliştirilmiş ResNet-50 Modeli" başlıklı makale, ResNet-50 mimarisinin görsel nesne tanıma görevlerinde etkinliğini artırmak için çok ölçekli bir dikkat mekanizması entegre ederek geliştirilmiş bir versiyonunu sundu.

#### **Temel Katkıları:**

**Çok Ölçekli Dikkat Mekanizması:** Makalenin temel yeniliği, ResNet-50 mimarisine çok ölçekli bir dikkat mekanizması entegre edilmesidir. Bu mekanizma, ağıın giriş görüntüsü üzerinde farklı uzamsal ölçeklerde önemli bölgelere odaklanmasını sağlar. Bu sayede, model hem ince detayları hem de genel özellikleri daha etkili bir şekilde yakalayabilir. Dikkat mekanizması, en önemli özelliklere vurgu yaparak, karmaşık görsel ortamlar içinde daha iyi tanıma performansı elde edilmesine olanak tanır.

**ResNet-50 Mimarisi İyileştirmesi:** ResNet-50 mimarisi, çok derin ağlarda kaybolan gradyan problemini çözmek için rezidüel bağlantılar kullanan bir yapıdır ve geliştirilmiş modelin temeli olarak kullanıldı. Çok ölçekli dikkatin entegrasyonu, ağıın farklı katmanlar arasında bağlamsal bağımlılıkları öğrenmesine olanak tanır; bu özellik, özellikle farklı boyutlardaki nesnelere veya karmaşık sahnelerin işlendiği durumlar için faydalıdır.

**İyileştirilmiş Görüntü Tanıma Yeteneği:** Çok ölçekli dikkatin entegrasyonu, modelin önemli özelliklere odaklanmasına yardımcı olur, böylece karmaşık görüntü veri setlerinde tanıma doğruluğu artırılır. Bu özellik, tıbbi görüntü analizi ve otonom sürüş gibi uygulamalar için oldukça değerlidir, çünkü model küçük, ince ya da örtüşen özellikleri tanımakta daha etkili olur.

**Deneysel Doğrulama:** Makale, önerilen modelin geleneksel ResNet-50 modellerine kıyasla birçok görüntü tanıma görevinde üstün performans sergilediğini gösteren ampirik sonuçlar sundu. Özellikle, farklı ölçeklerdeki nesnelere tanınmasını gerektiren zorlu veri setlerinde çok ölçekli dikkat mekanizması modelin doğruluğunu önemli ölçüde arttırdı.

Pratik Uygulamalar: Çok ölçekli dikkat mekanizmasına sahip geliştirilmiş ResNet-50 modeli, tıbbi görüntüleme (örneğin, tümör tespiti), otonom sürüş (örneğin, engel tespiti) ve güvenlik sistemleri (örneğin, gözetim) gibi hassasiyet gerektiren uygulamalarda önemli bir potansiyele sahiptir. Bu model, farklı ölçeklerdeki kritik bölgelere odaklanma yeteneği ile detaylı, bağlama dayalı tanıma yapılması gereken görevlerde özellikle uygundur.

Bu geliştirilmiş ResNet-50 modeli, görüntü tanıma için derin öğrenme modellerinin performansını önemli ölçüde artırmakta ve görsel veri analizi alanındaki pratik uygulamalarda daha verimli ve doğru modellerin kullanılmasını sağladı. Çok ölçekli dikkat mekanizmasının entegrasyonu, farklı uzamsal ölçeklerdeki desenleri tanıma konusundaki zorlukları ele alarak, yapay zekâ sistemlerinin karmaşık görsel veriyi daha etkili bir şekilde yorumlamasına olanak tanıdı.

#### **[7] Numaralı Yayın Referansdır**

Bhardwaj ve Sharma (2021) tarafından gerçekleştirilen çalışma, özellikle hastaneler gibi yüksek hassasiyet gerektiren sağlık ortamlarında maske algılama teknolojilerinin etkinliğini artırmaya yönelik derin öğrenme modellerinin optimizasyon stratejilerini ele alındı. Maske kullanımının kritik önem taşıdığı bu tür ortamlarda, doğru ve hızlı tespit sağlayacak algoritmaların geliştirilmesi, enfeksiyon kontrolü açısından temel bir gerekliliktir. Bu doğrultuda, çalışmada çeşitli optimizasyon teknikleri ve uygulama koşulları detaylı bir şekilde incelendi.

Araştırmada, derin öğrenme modellerinin performansını artırmak için hiper parametre ayarlamaları yapılmış; modelin her bir katmanındaki ağırlıkların en uygun şekilde belirlenmesi sağlanarak doğruluk oranlarının artırılması hedeflendi. Ayrıca, görüntü verilerinin çeşitlendirilmesine yönelik uygulanan veri artırma teknikleri sayesinde modelin genelleme kapasitesi güçlendirilmiş, aşırı öğrenmenin önüne geçilmiştir. Özellikle farklı açılar, ışık koşulları ve yüz pozisyonları altında oluşturulan örnekler sayesinde, gerçek hayattaki senaryolara daha uygun bir modelleme sağladı. Bunun yanı sıra, transfer öğrenme yaklaşımıyla önceden büyük veri kümeleriyle eğitilmiş modellerin ağırlıkları kullanılarak, sınırlı veriye rağmen hızlı ve etkili sonuçlar elde edildi.

Çalışma aynı zamanda, düşük ışık, yüz örtüşmesi ve kısmi maske kullanımı gibi hastane ortamlarında sıkça karşılaşılan zorlu çevresel koşullar altında model dayanıklılığını test edildi. Bu tür koşullar, maske tespitinin doğruluğunu doğrudan etkilediğinden, geliştirilen sistemlerin bu değişkenliklere karşı dirençli olması büyük önem taşır. Modelin çevresel faktörlere karşı gösterdiği uyum, hastane gibi yüksek hassasiyetli ortamlarda uygulanabilirliğini artıran temel bir unsurdur.

Model değerlendirmesi, doğruluk, hassasiyet ve geri çağırma gibi performans ölçütlerine dayandırılmıştır. Bu metrikler sayesinde hem genel başarı düzeyi hem de hatalı pozitif ve negatif sınıflandırmaların oranı analiz edildi. Bununla birlikte, gerçek zamanlı gözetimin önem kazandığı dinamik sağlık ortamlarında, işlem hızı da önemli bir değerlendirme kriteri olarak ele alındı. Çalışmada, modelin sadece doğruluk düzeyi değil, aynı zamanda pratikte ne kadar hızlı çalıştığı da ayrıntılı biçimde incelendi.

Elde edilen bulgular doğrultusunda, çalışma hastane ortamlarına özgü optimize edilmiş derin öğrenme mimarileri geliştirilmesini önerdi. Bu öneriler, yalnızca doğru maske tespiti sağlamakla kalmayıp, aynı zamanda çevresel değişkenliklere karşı sistemlerin esnekliğini de artırmayı hedefledi.

Bu bağlamda söz konusu makale, tez kapsamında ele alınan ResNet gibi derin öğrenme modellerinin değerlendirilmesi ve optimizasyon süreçlerinin açıklanmasında önemli bir referans niteliği taşıdı. Özellikle düşük ışık veya kısmi maske gibi zorlayıcı senaryolarda model performansının nasıl iyileştirilebileceğine ilişkin somut stratejiler sunması bakımından, çalışmanın yönetsel bölümünde destekleyici bir kaynak olarak kullanılabilir.

### **[8] Numaralı Yayın Referansdır**

Bu çalışma ile, yapay zekanın (YZ), hastanelerde enfeksiyon kontrol uygulamalarında yapılan iyileştirme potansiyelini araştırmakta ve özellikle merkezi hat ilişkili kan dolaşımı enfeksiyonları (CLABSI) ve kateter kaynaklı idrar yolu enfeksiyonları (CAUTI) gibi sağlık hizmetiyle ilgili enfeksiyonların (HAI) tespitindeki etkinliğini değerlendirildi. Araştırma kapsamında, biri OpenAI'nin ChatGPT'sine dayanan, diğeri ise açık kaynaklı bir model olmak üzere iki YZ aracı, simüle edilmiş klinik senaryolar üzerinde test edildiği anlaşılmaktadır. Bu çalışmada kullanılan yöntemler;

Yapay zekâ modelleri, CDC'nin Ulusal Sağlık Güvenliği Ağı gibi kapsamlı veri kaynakları kullanılarak geri alma-artırılmış üretim yöntemiyle eğitilmiştir. Bu süreçte veri kalitesinin kritik önemde olduğu vurgulanmış; eksik, belirsiz veya standart dışı veri girişlerinin YZ karar alma süreçlerini olumsuz etkilediği tespit edildi.

Çalışma bulgularına göre, YZ araçları eksiksiz ve doğru veri ile beslendiğinde enfeksiyon tespitinde yüksek doğruluk oranlarına ulaşıldı. Ancak tarih eksiklikleri veya tutarsız veri formatları gibi sorunlar, model performansını önemli ölçüde düşürdü. YZ'nin sunduğu en büyük avantajlardan biri, geleneksel hastane kaynaklı enfeksiyon (HAI) gözetim sistemlerine kıyasla daha az insan kaynağı gerektirmesi ve özellikle kaynakların sınırlı olduğu sağlık ortamlarında etkin bir çözüm sunabildi.

Bununla birlikte, YZ sistemlerinin güvenilirliğini sağlamak adına insan gözetimi hâlen kritik bir rol oynadı. Çalışmanın sonuçları, yapay zekânın enfeksiyon gözetiminde uygun maliyetli bir çözüm sunduğunu ve HAI'lerin daha hızlı, doğru tespiti sayesinde hasta güvenliğini artırabileceğini ortaya koydu. Ancak, modellerin doğruluğunu artırmak ve geliştirilebilirliğini sağlamak için gerçek hasta verilerinin entegrasyonu gerektiği de vurgulandı.

#### **[9] Numaralı Yayın Referansdır**

Adjabi, Ouahabi, Benzaoui ve Taleb-Ahmed (2020) tarafından kaleme alınan "Past, Present, and Future of Face Recognition: A Review" başlıklı çalışma, yüz tanıma teknolojilerinin tarihsel gelişimini, mevcut uygulamalarını ve gelecekteki potansiyel yönelimlerini kapsamlı bir şekilde ele aldı. Makalede, yüz tanıma sistemlerinin doğruluk ve güvenilirlik düzeylerini etkileyen temel faktörler incelenmiş; sistemlerin performansını şekillendiren teknolojik ilerlemeler ayrıntılı olarak değerlendirildi.

Çalışma, yüz tanıma teknolojisinin başlangıcından günümüze kadar geçirdiği evreleri ayrıntılı şekilde ortaya koyarak tarihsel bir çerçeve sundu. Özellikle derin öğrenme temelli yaklaşımların yüz tanıma performansı üzerindeki olumlu etkileri vurgulandı; bu yöntemlerin sistem doğruluğunu önemli ölçüde artırdığına dikkat çekildi. Bununla birlikte, yüz tanıma sistemlerinin karşılaştığı temel zorluklara da değinildi. Bu zorluklar arasında poz değişiklikleri, aydınlatma koşullarındaki farklılıklar ve özellikle pandemi sonrası önem kazanan maskeleme gibi faktörler ön

plana çıkarıldı. Bu deęişkenlerin sistem performansında neden olduęu sapmalar, geliştirilecek modellerin dayanıklılığı açısından kritik öneme sahiptir.

Makalede ayrıca, yapay zekâ teknolojilerinin gelecekte yüz tanıma sistemlerini nasıl şekillendireceğine dair öngörülere de yer verildi. Bu bağlamda, algoritmaların karar verme süreçlerindeki özerkliğinin artacağı, adaptif öğrenme sistemleriyle birlikte daha esnek ve çevik çözümler geliştirileceęi vurgulandı.

Bu çalışmanın tez kapsamında kullanım alanı, maskeli yüz algılama sistemlerinin mevcut sınırlılıklarının teorik olarak temellendirilmesi ve bu sınırlamaları aşmak için geliştirilen yöntemlerin daha geniş bir bağlamda değerlendirilmesi açısından önemlidir. Yüz tanıma teknolojisinin tarihsel gelişimini ve teknik engellerini kapsamlı bir şekilde açıklayan bu kaynak, özellikle maske gibi fiziksel engellerin sistem performansı üzerindeki etkisinin analiz edildięi bölümlerde teorik dayanak sağladı. Ayrıca, derin öğrenme tabanlı yöntemlerin yüz tanıma alanındaki mevcut rolü ve gelecekteki potansiyel katkılarına dair perspektif sunması bakımından da literatür taramasına deęerli katkılar sundu.

## 2. GÖRÜNTÜ İŞLEME VE YÜZ TARAMA

Görüntü işleme, dijital ortama aktarılmış görsellerin analiz edilmesi ve işlenmesi sürecinde kullanılan disiplinler arası bir yöntemdir. Temel amacı, görsellerin kalite ve kullanım uygunluğunu artırmaktır. Bu yöntem, çeşitli teknikler kullanılarak görsellerin değiştirilmesi, geliştirilmesi veya belirli bir uygulama için optimize edilmesini kapsar.

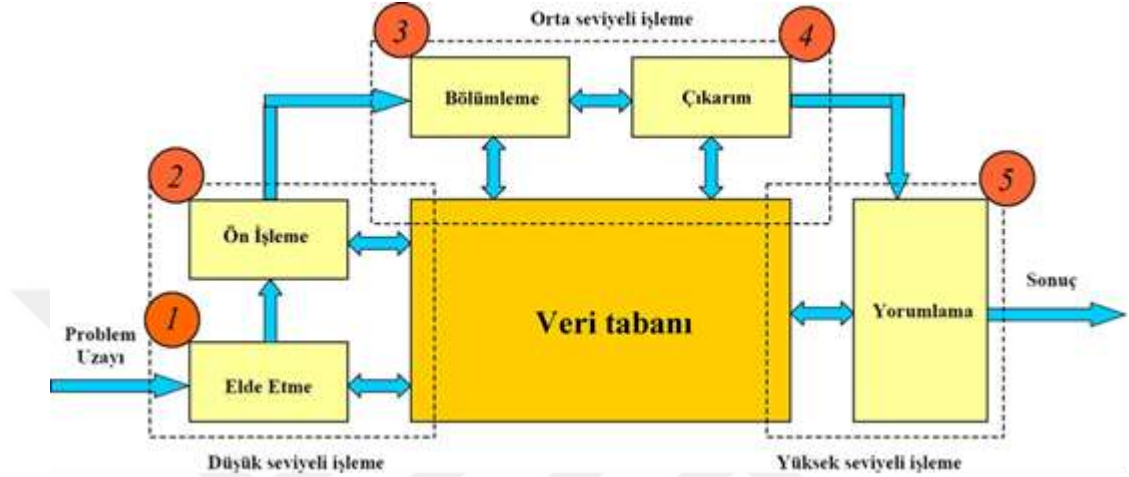
Örneğin, dijitalleştirilmiş belgelerde veya fotoğraflarda kalite kayıpları yaşanabilir. Bu kayıpların telafisi için görüntü işleme teknikleri devreye girer. Örneğin, taranan bir belge üzerindeki bozuklukları gidermek veya kontrastı artırmak için histogram eşitleme gibi yöntemler kullanılabilir. Ayrıca, Google Earth gibi uygulamalarda, uydulardan elde edilen ham veriler, görüntü işleme teknikleriyle düzenlenerek kullanıcılara yüksek kaliteli görseller sunulur.

Matematiksel olarak, görüntüler iki boyutlu sinyaller olarak ifade edilebilir ve bu nedenle lineer cebir temelinde matrislerle modellenir. Örneğin,  $[1080 \times 720]$  boyutlarında bir görüntü, 1080 satır ve 720 sütundan oluşan bir matris olarak temsil edilir. Görüntü işleme sürecindeki işlemler genellikle bu matrisler üzerinde gerçekleştirilir. Bu işlemlerde, konvolüsyon gibi matematiksel yöntemlerle çalışan filtreler sıkça kullanıldı. Filtreler, belirli bir matematiksel fonksiyon temelinde tasarlanır ve görüntüde istenen özellikleri ortaya çıkarmak veya belirli gürültüleri bastırmak için uygulanır.

Görüntü işleme teknikleri, mühendislik ve bilgisayar bilimleri gibi disiplinlerde yaygın bir araştırma konusu olup tıp, uydu görüntüleme, güvenlik sistemleri, biyometri ve endüstriyel otomasyon gibi pek çok alanda kritik öneme sahiptir. Bu nedenle hem teorik hem de pratik açıdan kapsamlı bir bilgi birikimi gerektirir.

## 2.1 Sayısal Görüntü İşleme

Sayısal görüntü işleme, analog bir görselin sayısal forma dönüştürülerek bilgisayarlar aracılığıyla iyileştirme, onarma, sınıflandırma, sıkıştırma, anlamlandırma ve yorumlama gibi çeşitli hedeflere yönelik işlenmesiyle ilgilidir. Ana adımları aşağıdaki görselde özet halinde verildi.



Şekil 2.1: Sayısal Görüntü İşleme [27]

Elde Etme: görüntü işlemenin ilk aşaması, sayısal bir görselin dijital kamera ile elde edildi.

Ön İşleme sayısal görselin elde edilmesinden sonraki adım, ön işlemdir. Bu aşamada, görselin doğrudan kullanılmadan önce daha iyi sonuçlar elde edebilmek için çeşitli işlemlerden geçirilmesi amaçlandı. Bu işlemler temelde Görüntünün iyileştirilmesi (image enhancement), Görüntünün onarılması (image restoration), Görüntünün sıkıştırılması (image compression) alt başlıklarıyla anlatılabilir. Görselin elde edilip ön işlemden geçirilmesi, alt seviye görüntü işleme olarak adlandırılır. [12]

Bölümleme ön işlemenin tamamlanmasının ardından, bölümleme (bölütleme, parçalama ya da segmentasyon) adımına geçilir. Bölümleme, görüntü işlemenin en zorlu aşamalarından biri olup, bir görseldeki nesnelerin arka plandan veya farklı özelliklere sahip bölgelerden ayrıştırılması sürecidir. Bu adım, görseldeki nesnelerin sınırlarını ve alanlarını belirleyerek ham veriler elde edilmesini sağladı.

Eğer nesnelerin şekilleri ile ilgileniliyorsa, bölümleme süreci kenar, köşe ve sınırlarla ilgili önemli veriler sunar. Ancak, nesnelerin yüzey yapısı, alanı, rengi veya iskelet gibi iç özellikleriyle ilgileniliyorsa, bölgesel bölümleme tercih edilmelidir.

Daha karmaşık sorunlar, örneğin karakter tanıma veya örüntü (pattern) analizi gibi durumlar söz konusu olduğunda hem sınır hem de alan bölümlene yöntemlerinin birlikte kullanılması daha etkili sonuçlar sağlar. Çıkarım görüntüden erişilen ilk verilen, ihtiyaç duyulan detayların başa alınmasıdır. Yani istenen özellikler bölümlerin arka plandan ve kendilerinden ayrıştırılması ile elde edilir.

Yorumlama yüksek seviye görüntü işleme aşamasında, farklı yöntemler (yapay zekâ algoritmaları gibi) kullanılarak, görselden ayrıştırılan nesne veya bölgeler etiketlenir ve sınıflandırılır. Bu adım, görüntüden anlamlı sonuçlar elde etmeyi amaçlar. [16]

## 2.2 Piksel Üzerinde Yapılan İşlemler


Görüntü işleme adımında yapılması gereken işlerin hepsi görseli oluşturmakta olan pikseller üstünde yani bu piksellerde bulunan renk bilgileri üstünde gerçekleşmektedir. Bu işlemler; nokta işlemi, yerel (bölgesel) işlem ve bütünsel işlemler olarak üç alan olarak görüldü.

Nokta İşlemleri çıkış görselinin bir pikselini oluşturabilmek amacıyla, giriş görselinin bir pikseli üstünde yapılacak olan işlemdir. Kendine yakın bulunan pikseller içerisinde ayrı bulunan piksellerin kendi renk bilgisi değiştirilmesi ile elde edilir. Yani girdi resmindeki her piksel üstünde yapılmış olan işlem çıktı resmindeki dönütü olan pikseli elde eder.

Yerel (Local) İşlemler yerel işlemde çıkış görselini oluşturmakta olan bir nokta renginin, giriş görselinde bu noktanın yanındaki komşusunun renk özellikleriyle de alakalıdır. Yakın komşusunun renk özelliklerine bağlı olacağı belirtilen maske boyutuna da bağlıdır. Bu maskeler, resimdeki bütün pikseller üstünde kaydırılması ile resmin filtrelenmesi sağladı. Bu açıdan; resimdeki bulanıklığın giderilmesi, gürültülerin temiz hale getirilmesi, kenar ve bölge özelliği belirlenmesi yerel işlem için birer örnek olacak şekilde gösterildi. Özetlemek gerekirse bu işlem sonucunda çıktı resmindeki bir piksel değeri girdi resmindeki birden fazla pikselin değeri ile ilişkilidir.

Bütünsel (global) İşlemler bütünsel (global) işlemlerde görselin bütün piksellerinin renk özellik durumları çıkış görselinin oluşturacağı pikseli

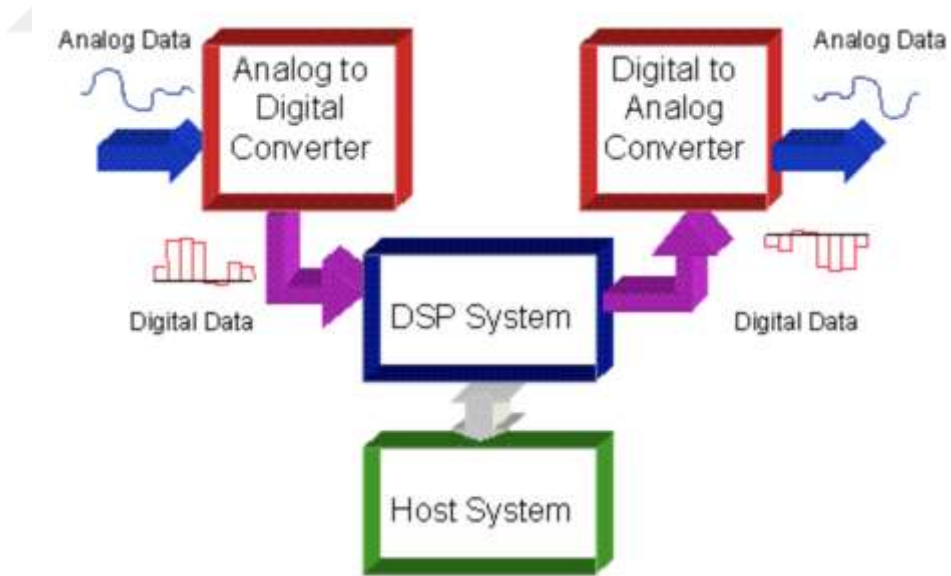
etkilemektedir. Yani bu işlemdeki çıktı resmindeki bir pikselin değeri girdi resmindeki bütün piksellerin çıkış değerleri ile ilişkilidir. [20]



Şekil 2.2: Piksel Değerleri [27]

### 2.2.1 Analog görüntünün sayısallaştırılması

Analog resimlerin bilgisayar alanında işleminden geçebilmesi için sayısallaştırılması gereklidir. Sayısallaştırma işleminde görseller üstünde konum anlamında örnekleme (sampling) ve renk derinlik değeri elde edilebilmesi için ise nicemleme (quantization/kuantalama) yapıldı. Görüntü fonksiyonlarına ilişkin koordinatlarının sayısal hale getirilebilmesi, görsel örnekleme şeklinde adlandırılıyor iken; genlik değerinin sayısallaştırılması işlemine görüntü nicemleme olarak tanımlanır. [19]



Şekil 2.3: Analog ve Dijital Görüntü [25]

### 2.2.2 Görüntü Örnekleme

Sayısal bir görsel, sürekli olan görsel fonksiyonu üstünden eşit aralıklar ile x-ekseni yönünde N adet örnek ve y-ekseni yönünde M adet örnek olarak oluşturuldu. Bu sayede, sürekli-zamanlı görsel fonksiyon üzerinden ayrık-zamanlı görsel

fonksiyona geme iřlemi gerekleřtirilmiř olacaktır. 2-B ayırık-zamanda yatayda N adet rnek ile oluřan toplamda  $N \times M$  sonlu rnek deęerle analog bir grsel takribi anlamda ifade edildi. Bu iřlem sayesinde, analog grsel iřlevi doęru rneklenebilmiř olacaktır. Yani doęru rnekleme, analog grnt ile hem yatay hem de dřeyde eřit aralıklar baz alınarak oluřturuldu. Oluřmakta olan dijital (sayısal) grsel, esasında N satır ve M stundan oluřan bir matristir. Bu iřlem ierisinde veri kaybolması bulundu.

### **2.2.3 Grnt nicemleme**

Grselin her bir parasının (pikselin) parlaklık řiddetini ifade eden pozitif tamsayı deęerleri, grntlerin sayısallařtırılması srecinde rnekleme ve nicemleme iřlemleri ile belirlendi. Nicemleme iřlemi, bir grntnn analog parlaklık deęerlerinin, belirli bir aralıkta en yakın dijital tamsayı deęerine dnřtrlmesi srecini kapsar. Bu iřlem, grntnn her bir parasına en uygun tamsayı deęerinin atanmasını saęlayarak grselin sayısal bir forma dnřtrlmesini mmkn kılar.

rnekleme ve nicemleme iřlemleri sonucunda oluřan sayısal grnt, piksel adı verilen elemanlardan oluřan iki boyutlu bir matrisle temsil edilir. Bu matrisin her bir bileřeni, bir pikselin parlaklık řiddetini ifade eden pozitif tamsayı bir deęeri ierir. Piksel, sayısal bir grnty oluřturan temel birimdir ve her pikselin sahip olduęu parlaklık deęeri, grntnn detaylarını tanımlamada kritik bir rol oynar. zellikle parlaklık řiddeti, grselin genlik aralıęının uygun řekilde blmlenmesi ve bu blmlere atanan dijital deęerlerle iliřkilidir.

Bu sreler, sayısal grnt iřlemenin temelini oluřturmakta olup, dijitalleřtirme sırasında kayıpları en aza indirmek ve grsel kalitesini artırmak iin geliřtirilmiř matematiksel yntemlere dayanır. Sayısallařtırılmıř grntler, bařta grnt iřleme, bilgisayarla grme ve makine ęrenimi gibi alanlarda yaygın olarak kullanıldı. [19]


### **2.2.4 Gri grnt**

Sayısala dnřtrme iřlemi esnasında, grsel boyutunun ve tm piksellerin sahip olabildięi parlaklık deęerlerinin belirlenebilmesi gereklidir. Sayısal grntnn tm piksel deęerlerinin barındırmakta olacaęı parlaklık oranı gri seviye řeklinde

isimlendirildi. Tüm pikselde bulunan parlaklık düzeyi kodlandığı bit sayılarına göre gri seviye aralığını belirler.

Gri seviye içerisinde siyah ve beyaz olacak şekilde iki renk bulundu. Bu iki renk ortasında kodlanmakta olan görsellere ise gri-ton (gray scale, monochromatic) görüntü şeklinde isimlendirildi.

Uygulama için sık sık kullanılmakta olan tüm piksel 8 bit şeklinde kodlandı. Bu tip görseller her bir piksel  $2^8 = 256$  değişik gri ton karşılığı (parlaklık düzeyi) değerlerinden oluşmakta ve gri değer aralığı  $G = \{0, 1, 2, \dots, 255\}$  şeklinde ifade edildi. Yapısal anlamda; 0 gri düzeyli siyah renk, 255 gri seviyesiyse beyaz renge ve bu değer aralığındaki gri seviyeleriye gri tonlu renklere karşılık geldi.



Şekil 2.4: Gri Görüntü [29]

### 2.2.5 Renkli görüntü

Renkli görseller, R(Kırmızı), G(Yeşil), B (Mavi) kodlarıyla ifade edilmiş benzer cisme ait üç tane gri seviyede görselin üst üste görüntüde gösterilmesiyle oluştu. Renkli görseli oluşturmakta olan bu üç renk bant olacak şekilde isimlendirildi.


Renkli görsellerin her bir pikseli bilgisayar ekranında 24 bit'lik data şeklinde görüldü. Şöyle ki, her bir renk 8 bit ( $2 \cdot 2 \cdot 2 \cdot 2 \cdot 2 \cdot 2 \cdot 2 \cdot 2 = 2^8 = 256$ ) ile kodlandığında üç renk (RGB)  $3 \times 8 = 24$  bit ile kodlanmış olacaktır. Bu sayede, RGB görsellerin her bir pikseli  $2^8 \times 2^8 \times 2^8 = 2^{24} = 16.777.216$  (tahmini 17 milyon) değişik renkte değere sahip olacak ve bu üç renk bir araya gelmesiyle değer aralık olarak  $RGB = (0, 0, 0)$ ,

..., (255, 255, 255) şeklinde gösterilecektir. Alttaki tabloda bazı örnek renk ve değer bilgilerini görebilirsiniz.

Matris olarak düşündüğümüzde doğal renkli 2 boyutlu bir RGB görseli, her biri  $(N \times M)$  boyutunda üç matris (ızgaranın) bir araya gelmesi ile oluşturuldu. Matris görselinde  $\{I(i, j, k) \mid i = 1, 2, \dots, N; j = 1, 2, \dots, M; k = 1, 2, 3\}$  şeklinde simgelendi. Genel anlamda bu matristeki her bir değer, pikseldeki 256 seviye içerisinden herhangi birisine sahip görüntüyle eşleştirilerek ifade edildi.

$I(i, j, 1); i = 1, 2, \dots, N, j = 1, 2, \dots, M \rightarrow$  Kırmızı banda ilişkin matris  $I(i, j, 2);$   
 $i = 1, 2, \dots, N, j = 1, 2, \dots, M \rightarrow$  Yeşil banda ilişkin matris

$I(i, j, 3); i = 1, 2, \dots, N, j = 1, 2, \dots, M \rightarrow$  Mavi banda ilişkin matris




Şekil 2.5: Üç Renk [27]

Renkli görselin yeşil ve mavi bandına ait görsellerin sıfır alınması ile yalnızca kırmızı bant görseli elde edilebilir. Bu sayede, RGB gösterilme işlemi kırmızı yapay renk verilmiş görüntüsü elde edilir. Bu şartlarda kodlama  $RGB = R00 = (0, 0, 0), \dots, (255, 0, 0)$  olarak ifade edilecektir. Aynı mantıkta, yeşil ve mavi yapay renklendirilecek olan görseller de sırası ile  $RGB = 0G0 = (0, 0, 0), \dots, (0, 255, 0)$  ve  $RGB = 00B = (0, 0, 0), \dots, (0, 0, 255)$  şeklinde olmaktadır. Bu formatta oluşacak olan yapay renklendirme görselleri alttaki gibi ortaya çıkacaktır.

RGB formatında doğal renklendirmeye sahip bir renkli görsel için bant aralıklarının doğru bileşimi, sırasıyla 1-2-3 (Kırmızı, Yeşil, Mavi) şeklinde olmalıdır.

Aşağıda, üç renk bileşiminin oluşturduğu doğal renkli görüntünün gri tonlamalı hali ile her bir renk bandına ait ayrı ayrı gri-ton görüntüleri gösterildi.



**Şekil 2.6: Gri Ton Renklendirme [28]**

Eğer RGB gösteriminde bant bileşimlerinin alanlarını değiştirmek gerekirse renkler de otomatik farklılaşacaktır. Bu yöntemle oluşacak olan görsellere yapay renkli görsel olarak isimlendirildi. [22]

## 2.3 Bellek Alanı

### 2.3.1 Sayısal görüntünün kapladığı bellek alanı

N satır ve M sütundan oluşmakta olan ve tüm pikseli m bitle temsil eden ( $N \times M$ ) boyutlu sayısal bir görseli depolamak için ihtiyaç duyulan bit sayısı alttaki şekilde hesaplandı:

$$\text{Bit sayısı} = N \times M \times m$$

$$8 \text{ bit} = 1 \text{ byte}, 1024 \text{ byte} = 1 \text{ Kbyte}, 1024 \text{ Kbyte} = 1 \text{ Mbyte} \text{ olarak hesaplanır.}$$

Örnek olarak tüm piksel 8 bit ile temsil edilecek olan Gri bir görsel  $N \times M = 1000 \times 600$  piksel boyutlarındaysa

$$b(\text{toplam bit}) = 1000 \times 600 \times 8 = 4.800.000 \text{ bit}$$

$$\text{Byte} = 4.800.000 / 8 = 600.000 \text{ byte}$$

$$600.000 \text{ byte} = 600 \text{ Kbyte} = 0,6 \text{ Mbyte} \text{ olacaktır. [18]}$$

Aynı görsel 24 bit üzerinden kodlamayla (renklendirilmiş görsel) depolar isek (tüm piksel  $\text{RGB} = 2^8 \times 2^8 \times 2^8 = 2^{24} = 16.777.216$  milyon renkle gösterilecektir)

$$b(\text{toplam bit}) = 1000 \times 600 \times 24 = 14.400.000 \text{ bit}$$

$$\text{Byte} = 14.400.000 \text{ bit} / 8 = 1.800.000 \text{ byte}$$

1.800.000 byte=1.800 Kbyte=1,8 Mbyte olur.

Tüm piksel kodlayabilmek adına ihtiyaç duyulan bit adedi büyüdükçe görseli depolayabilmek amacıyla ihtiyaç duyulan bellek alanı da yükselmektedir. Bu durum neticesinde, renkli görseller, gri-ton görsellere kıyasla bellek olarak bilgisayarda daha çok alan kapladı.

Örneğin; 8 bitlik bir görsel 3Mbyte oluştururken, gri-ton bir görsel için ise 1Mbyte'dır. [18]

### 2.3.2 Çözünürlük

Bir görselin çözünürlüğü, içeriğindeki ayrıntıların algılanabilirliği ile doğrudan ilişkilidir, bunlar alan çözünürlüğü ve parlaklık çözünürlüğü şeklinde iki temel bileşeni içerirler. Alan çözünürlüğü, bir yüzey alanından alınan örnek sayısı ile ifade edilir ve genellikle  $N \times M$  biçiminde tanımlandı. Bu, görüntünün yatay ve dikey eksenlerindeki toplam piksel sayısını temsil eder. Parlaklık çözünürlüğü ise, bir pikselin parlaklığını tanımlayan ve gri tonlama seviyesine karşılık gelen değerleri ifade eder.

Her iki çözünürlük parametresinde de değerlerin artışı, sayısallaştırılmış görüntünün orijinaline daha yakın bir form kazanmasını sağladı. Ancak, bu durum aynı zamanda görselin bellek kullanımını da önemli ölçüde arttırdı. Alan çözünürlüğündeki artış, görüntüde daha fazla piksel bulunmasına neden olurken, parlaklık çözünürlüğündeki artış, her bir pikselin daha hassas parlaklık seviyeleriyle ifade edilmesine imkân tanıdı. Bu denge, yüksek kaliteli görüntü işleme süreçlerinde önemli bir optimizasyon problemi.

Çözünürlük parametrelerinin uygun şekilde seçilmesi, görüntülerin analizi, işlenmesi ve depolanması sırasında performansı artırmak için kritik bir öneme sahiptir. Özellikle, sınırlı bellek kapasitesine sahip sistemlerde, çözünürlük seçimi, kalite ve depolama alanı arasında bir denge oluşturmayı gerektirir.

### 2.3.3 Alan hassaslığı (piksel çözünürlüğü)

Alan hassaslığı, sayı değerlerinden görseli elde edebilmek amacı ile analog görselin yatay/dikey taranmasıyla toplanmakta olan örnek sayısı ile ilişkilidir. Sayısal görseli oluşturmakta olan piksel adedi ( $N \times M$ ) hangi oranda çok olur ise orijinal (analog) görsele o oranda çok yaklaşacaktır. Öbür yandan, piksellerin sayısının

azalması durumunda görselin uzaysal çözünürlük oranı düşecek ve görsel içindeki detaylar azalmaya başlayacaktır. Bu olay dama tahtası etkisi (checker board effect) şeklinde isimlendirildi. Bu etki, görsel içindeki yapay kare oluşmasıyla neticelendi. Aşağıdaki görselde farklı alan çözünürlüğü içeren 8 bit gri-ton görseller gösterildi. Görselden de görüldüğü gibi, piksel adedi düştükçe, dama tahtası etkisi büyüdü. [18]

### 2.3.4 Parlaklık hassaslığı

Parlaklık hassaslığı, her bir pikselin parlaklığına karşılık gelen gri seviye skalasında bulunan sayıyı ifade eder. Burada gri seviye skalası siyah renkten beyaz renge doğru renk açılıyorken 256 adet adım (8 bit) kullanıldı. Bu skaladaki gri renk yerine, herhangi bir renk değeri karşılığı o rengin parlaklık düzeyini gösterir.

Öncesinde de belirtildiği gibi, uygulamalarda sık şekilde kullanılmakta olan gri-ton görsellerin gri düzey manasında net parlaklık değeri 255 olmakta, bu değer beyaz renge karşılık geldi. Yani, bu tip görsellerin pikselleri  $G = \{0, 1, 2, \dots, 255\}$  gri seviye aralığında olmak üzere 256 değişik değer alabilmekte ve neticede her bir piksel  $m = 8$  bit ile ifade edildi. Gri seviye görsellerin adeti düştükçe, görsel içindeki yapay çizgisel sınırlar meydana çıkmaya başlayacaktır. Aşağıda şekilde 256 renk (8 bit), 128 renk (7 bit), 64 renk (6 bit), 32 renk (5 bit), 16 renk (4 bit), 8 renk (3 bit), 4 renk (2 bit) ve 2 renk (1 bit) olan aynı alan çözünürlüklü ( $N \times M = 256 \times 256$ ) gri-ton görseller gösterildi. [13]



Şekil 2.7: Hassasiyetlik [24]

### 2.3.5 Uygun çözünürlük değerlerinin belirlenmesi

Dijital görüntülerin bir aygıtta işlenebilmesi için sayısal örneklerle temsil edilmesi gerekliliği, görüntü işleme disiplininin temel taşlarından biridir. Görselin

boyutu, örnekleme (sampling) işlemi ile belirlenen örnek sayısı ile doğrudan ilişkilidir. Örnekleme işlemi, analog bir görselin belirli bir sayıda örnekleme noktası üzerinden sayısallaştırılmasını ifade eder. Görüntünün her bir örnekleme noktasındaki gri ton seviyeleri ise nicemleme (quantization) işlemi ile sınırlı bir sayı aralığında temsil edilir.

Bir analog görselin en yakın dijital karşılığını oluşturabilmek için örnekleme ve nicemleme parametrelerinin doğru seçilmesi kritik öneme sahiptir. Bu parametrelerin artırılması, görüntünün çözünürlüğünü ve doğruluğunu artırsa da, depolama alanı gereksinimi ve işlem süresi üzerinde olumsuz etkiler yaratır. Bu nedenle, işlem sırasında hem yüksek çözünürlük hem de minimum kaynak kullanımı sağlanabilecek optimal değerlerin belirlenmesi gereklidir.

Teorik olarak, analog bir sinyali dijital bir sinyale doğru şekilde dönüştürmek için örnekleme frekansının Nyquist sınırını karşılaması gereklidir. Nyquist teoremi, örnekleme frekansının, sinyaldeki maksimum frekansın en az iki katı olması gerektiğini ifade eder. Eğer örnekleme frekansı bu sınırın altına düşerse, aliasing olarak bilinen bir bozulma meydana gelir ve sinyaldeki bilgiler geri döndürülemez şekilde kaybolabilir. Fourier analizi, bu bağlamda görsellerin bant genişliği çerçevesinde düşük geçişli filtreleme yapılması halinde hata oranının minimuma indirilebileceğini belirtir.

Bu bilgiler ışığında, örnekleme frekansı ve nicemleme seviyelerinin uygun değerlerde seçimi hem görsel kalitenin korunmasını hem de işlem verimliliğinin sağlanmasını mümkün kılar. Bu optimizasyon, dijital görüntü işleme uygulamalarında temel bir tasarım gerekliliğidir. [18]

### **2.3.6 Yüz tarama yöntemi**

Yüz algılama ve tanıma teknolojisi, bir görüntüdeki veya videodaki bireylerin kimliklerinin belirlenmesi veya yüz özelliklerinin analiz edilmesi için kullanılan bir sistemdir. Özellikle yüz tanıma, gerçek zamanlı olarak yüzleri algılama, maske tespiti yapma gibi çeşitli uygulamalarda kullanıldı. Son altmış yılda bu teknoloji, kolluk kuvvetlerinden bankacılığa kadar pek çok endüstride önemli bir yere sahip oldu.

Yüz algılama sistemlerinde, görsel verilerin sayısal ortama aktarımı sürecinde örnekleme ve nicemleme gibi dijital sinyal işleme tekniklerinden yararlanıldı; bu

sayede yüz özellikleri daha hassas biçimde analiz edilebildi. Söz konusu sistemler, genellikle FERET gibi kapsamlı veri tabanları kullanılarak eğitildi ve optimize edildi. Uygulama alanları arasında; kolluk kuvvetleri ve güvenlik (örneğin, şüpheli takibi ve sınır güvenliği), bankacılık ve finans (kimlik doğrulama ve güvenli ödeme sistemleri), perakende sektörü (müşteri davranışlarının analizi) ve mobil teknolojiler (yüz tanıma tabanlı cihaz güvenliği) yer aldığı görüldü.

Bu sistemlerin gelişimi, teknolojik yenilikler ve büyük veri tabanları sayesinde hızlandı, uygulama alanları genişledi. Özellikle derin öğrenme algoritmalarının uygulanması, yüz tanımanın doğruluğunu ve güvenilirliğini önemli ölçüde arttırdı.



**Şekil 2.8: Yüz Tarama Bilgisi [34]**


Yüz maskesi algılama, teknik olarak zorlu bir süreç olup, mevcut yüz algılama modellerinin özel olarak uyarlanmasıyla gerçekleştirilebilir. Bu süreç, genel yüz algılama sistemlerinin temel prensiplerini takip etmekte, ancak ek olarak maskelerin varlığını tespit etmeye yönelik işlemleri içerir. Yüz maskesi algılama sistemi şu temel bileşenlere dayandı:

Görüntü işleme süreci kapsamında, ilk olarak yüzün algılanması işlemi gerçekleştirilir; bu aşamada, yüz algılama algoritmaları kullanılarak görüntüdeki yüz bölgeleri tespit edilir ve bu bölgeler önceden eğitilmiş veri kümelerindeki yüz örnekleriyle karşılaştırılarak doğrulama sağlanır. Yüzün başarıyla tespit edilmesinin ardından, bireyin maske takıp takmadığının belirlenebilmesi amacıyla maskenin algılanması aşamasına geçilir. Bu aşamada, özellikle yüzün alt kısmına ait görsel veriler üzerinde detaylı bir özellik analizi yapılır ve bu analiz çoğunlukla derin

öğrenme tabanlı sınıflandırma modelleri aracılığıyla gerçekleştirilir. Son olarak, karşılaştırma ve çıktı üretimi aşamasında, elde edilen yüz özellikleri eğitim sırasında kullanılan veri kümeleriyle kıyaslanır; bu doğrultuda sistem, kişinin maske takıp takmadığını belirleyerek uygun bir çıktı (örneğin, "Maske takınız" uyarısı) üretir.

Bu tür sistemler, veri setlerinin çeşitliliği ve boyutuna oldukça bağımlıdır. Algoritmaların, farklı maske türlerini, renklerini ve konumlarını doğru bir şekilde algılayabilmesi için geniş bir veri yelpazesine eğitilmiş olması gereklidir. Bu teknoloji, özellikle halk sağlığı önlemleri kapsamında etkili bir şekilde kullanıldı.

[14]



**Şekil 2.9: Yüz Maskesi Tarama Bilgisi [33]**

Derin Öğrenme (DL) temel olarak Makine'nin (Machine) bir alt bölümüdür. Algoritmaları içeren Makine Öğrenme (ML) modeli yapısından ilham alan algoritmalarla ilgilidir ve beynin işlevi ve yapay sinir ağları olarak adlandırılan çok katmanlı sinir ağlarını kullanıldı. [21]

Temel olarak, DL ve ML, daha yüksek yapay zekâ alanına aittir (AI). DL, Sinir Ağına bağlıdır ve girdiyi bir şekilde üretmek için dönüştüren katmanların işleyişini gerçekleştirdi ve çıktıyı oluşturdu. Derin öğrenmede, Görüntü "piksel değerleri matrisi" olarak adlandırılabilir, bu nedenle karmaşık görüntü matrisini veya görüntüleri sınıflandırmak daha kolaydır. Benzer matris formları veya çok büyük bir görüntü veri seti ile derinliğe bağlı olarak matriste minimum değişikliklerle öğrenme matrisi sınıflandırıldı. Bu çatışmaya neden olabilecek unsurlar, tahmin puanlarını ve dolayısıyla doğruluğu etkileyen faktörler ile sınıflandırıcı modelin hızı şeklinde iki ana başlıkta ele alındı.


Yüz tarama işlemi, yüz tanıma sistemlerinin temel bileşenini oluşturmaktadır. Bu sistemlerin çalışma prensibi genellikle altı ana aşamadan oluşur. Bu aşamalar, algoritmik işlemler ile kullanıcı odaklı çıktılar arasında işlevsel bir köprü kurarak, sistemin etkinliğini ve doğruluğunu sağlar.

Yüz tanıma sistemlerinde süreç, öncelikle analiz için gerekli görsel verinin temin edilmesiyle başlar. Bu aşama, görselin elde edilmesi süreci olarak tanımlanmaktadır; sistem sabit bir görüntü (örneğin fotoğraf) ya da hareketli bir video kaydı aracılığıyla yüz bilgisini dijital ortama aktarır. Bu veriler genellikle güvenlik kameraları ya da yüz tanıma işlevine özel donanımlarla sağlanır. Görsel verinin alınmasını takiben, sistemin yüz tanıma performansını artırmak amacıyla erişim ve görüntüleme hazırlığı gerçekleştirilir. Bu hazırlık sürecinde kamera açısı, aydınlatma koşulları gibi çevresel faktörler optimize edilir ve yüzün net bir şekilde algılanabilmesi sağlanır.

Devamında, sistem tarafından elde edilen görüntü üzerinde referans noktalarının algılanması işlemi gerçekleştirilir. Bu işlem, yüzün temel anatomik bölgelerinin (örneğin gözler, burun ve ağız) tespitiyle gerçekleşir ve bu referans noktaları yüzün geometrik olarak modellenmesine olanak tanır. Ardından, sistem elde edilen bu model üzerinden veri analizi ve karşılaştırma sürecine geçer. Bu aşamada, algılanan yüz yapısı daha önce sisteme tanıtılmış yüz profilleriyle veya referans veri setleriyle karşılaştırılarak maske kullanım durumu tespit edilir.


Eğer maske kullanılmadığı belirlenirse, sistem uyarı ve güvenlik tedbirleri kapsamında kullanıcıyı sesli veya görsel bildirim yoluyla bilgilendirir ve gerekirse erişim kontrol sistemleri gibi önlemler devreye alınır. Son olarak, sistem çoklu işlem ve entegrasyon yetenekleri doğrultusunda diğer güvenlik modülleriyle etkileşim hâlinde çalışarak bütünsel bir güvenlik çözümü sunar. Örneğin, maskesiz bir birey tespit edildiğinde otomatik kapı sistemlerinin kilitlemesi veya ilgili güvenlik birimlerine anlık uyarı gönderilmesi mümkün hale gelir.

Bu süreç, gelişmiş algoritmalar ve yapay zekâ modelleri kullanılarak optimize edilir. Yüz tarama sistemleri; sağlık, güvenlik ve erişim kontrolü gibi alanlarda yaygın bir şekilde kullanılmakta olup, özellikle pandemi döneminde maskeli yüz algılama özelliği ile ön plana çıktı.



**Şekil 2.10: Yüz Tarama Sistemi [36]**

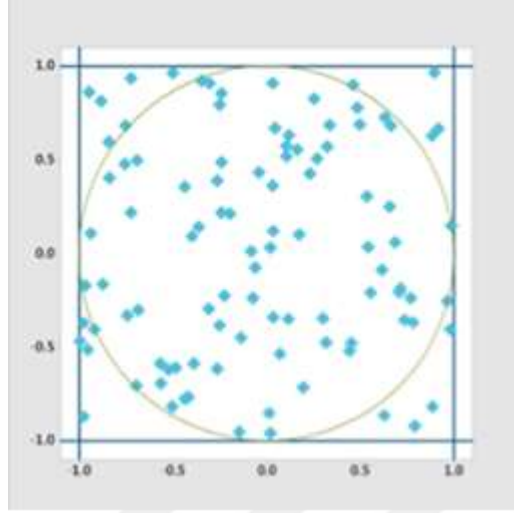
Monte Carlo yöntemiyle yarıçapı 1 birim olan bir çember üstünde ve dışarıdan alınan rastgele  $(x,y)$  koordinatlarına sahip  $n$  nokta için  $\pi$  değerinin tahmini değeri hesaplanabilecektir.



**Şekil 2.11: Pi Grafiği [31]**

Öncelikle, yarıçapı 1 birim olan bir çember, kenar uzunluğu 1 birim olan bir karenin içerisine yerleştirildi. Daha sonra, bu kare üzerinde rastgele  $n$  adet nokta seçilerek, noktalardan kaç tanesinin çemberin içinde yer aldığı tespit edilir. Uygulamalı bir deney gerçekleştirilmek istenirse, bu işlem fiziksel olarak, üzerine çember ve kare çizilmiş bir düzleme rastgele  $n$  adet pirinç tanesi bırakılarak da gerçekleştirilebilir.

Çemberin içinde kalan nokta (veya piriç tanesi) sayısı, belirli olasılık yöntemleriyle pi sayısının yaklaşık değerinin hesaplanmasında kullanılabilir.



**Şekil 2.12: Piriç Tanesi Modeli [32]**

Bu bulduğumuz değerden sonra artık genelleştirilmiş Monte Carlo formülünü kullanabiliriz. Bu değere göre pi değerinin tahmini değeri noktalar cinsinden şu şekildedir:

$$\pi \approx 4x \frac{\text{Çemberin İçindeki Nokta Sayısı}}{\text{Tüm Noktaların Sayısı}} \quad (2.1)$$

Nokta sayısı ne kadar çok ise, Pi'nin tahmini değerini bulabilmek o kadar zor hale gelir. Bundan dolayı, bu uygulama yazılım ortamına aktarılarak nokta sayısı çoğaltılabilecek şekilde modeller oluşturulur.

Burada ilk yapılması gereken iş değişkenlerin belirlenmesidir. Varsayalım değişkenler x ve y olsun. Bu değişkenleri her bir noktanın koordinatları olan (x,y) ikilisi için kullanılsın. İkincil durumda ise yazılım noktanın içerisinde mi yoksa dışarıda mı olduğunun fark edilebilmesini sağlayacak şartı belirlenir. Bir nokta çemberin içindeyse bu noktanın merkeze olan uzaklığı yarıçaptan küçük olmalıdır. Yani:  $x^2 + y^2 < 1$  şeklindedir. [10]

### 3. METODOLOJİ, SONUÇ VE ÖNERİLER

#### 3.1 Sistemsel Metodoloji

Bu tez çalışmasında, hastane ortamlarında yüz maskesi tespiti için geliştirilen sistemin metodolojik yaklaşımı, derin öğrenme tabanlı modelin tasarımından, donanım performansının değerlendirilmesine ve optimize edilmesine kadar bir dizi adımda ele alındı. Sistemsel metodoloji, üç ana aşamadan inceledi: veri toplama ve ön işleme, model geliştirme ve eğitimi ile performans analizi ve optimizasyon konularını içerdi.

##### 3.1.1 Veri toplama ve ön işleme

Yüz maskesi tespiti için doğru ve etkili bir model geliştirebilmek adına, geniş bir veri setine ihtiyaç duyuldu. Bu çalışmada, çeşitli maskeli ve maskesiz yüz görüntülerinden oluşan, Kaggle platformunda yer alan "Face Mask Detection" veri seti kullanıldı. Veri setinin kalitesini artırmak için görüntü işleme tekniklerinden yararlanıldı. Veri ön işleme aşamasında, resimler normalize edilerek modelin daha hızlı ve doğru öğrenmesi sağlandı. Ayrıca, veri artırma (data augmentation) yöntemleri (örneğin, yansıma, döndürme, çarpıtma) kullanılarak modelin genelleme yeteneği güçlendirildi. Böylece, eğitim seti üzerinde çeşitlilik yaratıldı ve modelin farklı koşullara daha dayanıklı olması sağlandı. [10] Bu çalışmada kullanılan görüntü verileri, Kaggle platformundan temin edilen açık kaynaklı bir yüz maskesi veri setinden elde edildi. Veri seti, maskeli ve maskesiz insan yüzlerini içeren ve XML formatında anotasyonlar içeren görsellerden oluştu. Anotasyon dosyaları, her bir görseldeki yüz bölgesini ve maskeli/maskesiz etiketlerini içerecek şekilde hazırlandı.

Ham verilerin işlenmesi üç aşamada gerçekleşti:

Yüz Tespiti ve Kırpma:XML formatındaki anotasyon dosyaları, Python'da xml.etree.ElementTree kütüphanesi kullanılarak ayrıştırıldı ve veriler elde edildi. Her bir görselde yer alan yüz nesnesinin bndbox (bounding box) koordinatları hesaplandı ve yüz bölgesi kare formatta kırıldı. Yüzler 128×128 çözünürlüğe ölçeklendirildi ve

maskeli (with\_mask) ile maskesiz (without\_mask) etiketlerine göre ilgili dizinlere (Dataset/Images/WithMask, Dataset/Images/WithoutMask) kaydedildi. Bu işlem sonucunda toplam 768 adet maskeli ve 735 adet maskesiz yüz görseli elde edildi.

Veri Setinin Eğitim ve Test Olarak Ayrılması:Görseller rastgele karıştırıldı ve %95'i eğitim, %5'i test veri setine ayrıldı.

Eğitim seti: 730 adet maskesiz, 1430 adet maskeli görsel

Test seti: 36 adet maskesiz, 38 adet maskeli görsel

Bu işlem shutil ve random kütüphaneleri aracılığıyla yapıldı, tqdm ile işlem süreci takip edildi.

Veri Dönüşümleri (Transformasyonlar):Eğitim sürecinde modelin genelleme yeteneğini artırmak amacıyla görüntülere çeşitli veri artırma (augmentation) işlemleri uygulandı:

Yatay çevirme (RandomHorizontalFlip)

Renk değişimi (ColorJitter)

Perspektif bozulması (RandomPerspective)

Normalizasyon

Bu dönüşümler torchvision.transforms bileşeni ile tanımlandı. Test verisine yalnızca yeniden boyutlandırma ve normalizasyon uygulandı.

Bu dönüşümler torchvision.transforms bileşeni ile tanımlandı. Test verisine yalnızca yeniden boyutlandırma ve normalizasyon uygulandı.

Veri artırma işlemi sonucunda, eğitim setindeki görüntü sayısı maskeli ve maskesiz yüz sınıflarında artırılarak toplam 2.160 adet eğitim verisi elde edilmiştir. Başlangıçta 768 maskeli ve 735 maskesiz yüz görüntüsü olmak üzere toplam 1.503 orijinal veri bulunduğu göz önünde bulundurulduğunda, 657 adet sentetik (üretilmiş) örnek oluşturulduğu anlaşılmaktadır. Bu sayede, özellikle maskeli sınıfın örnek sayısının artırılmasıyla, sınıflar arasında daha dengeli bir dağılım sağlanmış ve modelin sınıf bazlı genelleme yeteneği geliştirilmiştir.

### **3.1.2 Model geliştirme ve eğitimi**

Maske tespiti için derin öğrenme tabanlı ResNet (Residual Networks) modelleri seçilmiştir. ResNet, katman sayısı arttıkça ortaya çıkan kayıp sorunlarını çözme yeteneği sayesinde derin ağlarda yüksek başarı gösteren bir modeldir. Bu model, maskeli yüz tespiti gibi görevlerde daha yüksek doğruluk oranlarına ulaşmayı hedeflendi. Eğitim sürecinde, cross-entropy loss gibi kayıp fonksiyonları ve adam optimizer gibi optimizasyon algoritmaları kullanılarak, modelin en uygun ağırlıklarla eğitilmesi sağlanmaktadır. Eğitimin başlangıcında, modelin aşırı uyum (overfitting) yapmasını engellemek için erken durdurma (early stopping) ve dropout gibi teknikler uygulandı.

### **3.1.3 Donanım performans değerlendirmesi**

Maske tespiti sisteminin performansı, kullanılan donanımın özelliklerine bağlı olarak değişti. Bu sebeple, modelin CPU ve GPU üzerindeki performansı karşılaştırıldı. CPU, daha düşük maliyetli ve yaygın olarak bulunan bir donanım seçeneği; GPU, yoğun hesaplamalı işlemler için daha yüksek hız ve verimlilik sundu. Bu değerlendirme sırasında, her iki platformda sistemin kare hızı (FPS), doğruluk oranı, işlem süresi ve enerji tüketimi gibi metrikler ölçüldü ve karşılaştırıldı. Bu analiz, her iki platformun güçlü ve zayıf yönlerini ortaya koydu ve hangi durumlarda hangi donanımın daha verimli olduğunu belirlemeye olanak sağladı.

### **3.1.4 Model ve donanım optimizasyonu**

Hastane ortamlarındaki farklı kullanım senaryolarına göre modelin optimizasyonu bu çalışmada gerçekleştirildi. Örneğin, ameliyathane gibi hassas ve yüksek doğruluk gerektiren ortamlarda modelin doğruluğu ön planda tutuldu. Buna karşılık, bekleme salonu gibi daha yoğun ancak daha az hassasiyet gerektiren alanlarda hız ön plana çıkarıldı. Bu nedenle, her iki senaryo için farklı model yapılandırmaları ve donanım seçenekleri üzerinde analizler yapıldı. Modelin doğruluğunu artıran ya da hızını iyileştiren ayarlar belirlendi ve gerçek zamanlı maske tespiti uygulamaları için en uygun yapılandırmalar önerildi.

### **3.1.5 Hız-doğruluk-maliyet dengesi**

Sistem tasarımında, hız, doğruluk ve maliyet arasındaki dengeyi sağlamak önemli bir faktör oldu. Bu tezde, yüksek doğruluk oranı sağlamak için gerekli olan işlem gücünün sistemin hızını nasıl etkilediği analiz edildi. Ayrıca, hastaneler gibi kısıtlı bütçelere sahip ortamlarda uygulanabilirliği artırmak amacıyla, düşük maliyetli donanımlarla yüksek doğruluk ve hız sunabilen yapılandırmalar önerildi. Çalışmada, modelin doğruluğu artırılırken aynı zamanda işlem süresi ve maliyet gibi faktörlerin de optimize edilmesi hedeflendi.

### **3.1.6 Gerçek zamanlı uygulamada test ve değerlendirme**

Geliştirilen maske tespiti sisteminin gerçek zamanlı çalışabilmesi için testler yapıldı. Testler sırasında, sistemin farklı ortam koşullarında nasıl performans gösterdiği ve çeşitli kullanıcı senaryolarında ne kadar doğru sonuçlar verdiği değerlendirildi. Ayrıca, modelin gerçek dünya ortamlarındaki doğruluğu, hızı ve işlem süresi gibi metriklerle test edildi ve sonuçlar detaylı bir şekilde raporlandı.

### **3.1.7 Uygulama ve entegrasyon**

Bu tez çalışmasında geliştirilen maske tespiti sistemi, pratikte kullanılabilir bir uygulama olarak tasarlandı. Uygulama, hastane gibi yüksek güvenlik gereksinimlerine sahip ortamlara entegre edilebilecek şekilde geliştirildi. Ayrıca, sistemin kullanıcı dostu bir arayüzle desteklenmesi, sahada etkin bir kullanım sağlamak açısından önemli görüldü. [10]

### **3.1.8 Eğitim süreci ve kayıp fonksiyon analizi**

Model eğitimi sürecinde her bir ResNet mimarisi (18, 34, 50, 101, 152) için hem ön eğitilmiş (pretrained) hem de sıfırdan eğitilmiş (untrained) sürümlerle çalışıldı. Her konfigürasyon 100 epoch boyunca eğitildi. Bu da toplamda 10 farklı model kombinasyonu  $\times$  100 epoch = 1000 epoch'luk bir eğitim süreci anlamına geldi.

Eğitim süreci boyunca modelin kayıp (loss) değerleri dikkatle takip edildi. Bu değerler, modelin öğrenme performansı hakkında doğrudan bilgi verdiği için önemli bir izleme kriteri oldu. Gözlemler şu şekilde özetlendi:

Başlangıçta loss değeri yaklaşık 0.9 civarındaydı ve yüksek hata oranına işaret etti.

İlk 20 epoch içinde, kayıp değerinde hızlı bir düşüş gözlemlendi; bu durum, modelin temel öğrenme sürecini başarıyla gerçekleştirdiğini gösterdi.

50. epoch sonrası, loss değeri 0.1'in altına düştü ve model daha kararlı bir öğrenme dönemine girdi.

100. epoch sonunda, Train Loss  $\approx 0.02$  ve Test Loss  $\approx 0.03$  seviyelerine sabitlendi.

Bu değerler, modelin aşırı öğrenme (overfitting) göstermeden istikrarlı bir şekilde öğrendiğini ve hem eğitim hem de test verisinde yüksek performans sergilediğini gösterdi.

Bu çalışmada ResNet mimarilerinin tercih edilme nedeni, derin yapılarla çalışırken eğitim kararlılığını ve yüksek doğruluğu birlikte sunabilmesidir. Özellikle skip connection (artık bağlantılar) yapısı sayesinde, klasik konvolüsyonel mimarilerde karşılaşılan azalan gradyan (vanishing gradient) problemi büyük ölçüde azaltıldı. VGG, Inception veya DenseNet gibi alternatif modellerle karşılaştırıldığında; ResNet, daha optimize bir parametre yapısı, transfer learning'e uygunluğu ve farklı derinlikteki varyantları sayesinde uygulama senaryosuna özel konfigürasyon imkânı sunduğu için bu tez kapsamında en uygun seçenek olarak belirlendi.

### 3.1.9 Model performans analizi ve değerlendirme

Makine öğrenmesi modellerinin performansını yalnızca doğruluk (accuracy) ile değerlendirmek, özellikle sınıf dengesizliğinin olduğu durumlarda yetersiz kaldı. Bu nedenle, precision (kesinlik), recall (duyarlılık) ve F1-score gibi daha ayrıntılı metriklerin kullanılması gerekti. Bu bölümde, söz konusu metriklerin tanımları, önemi ve çalışmada nasıl kullanıldıkları açıklandı.

1. Precision (Kesinlik), modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösterdi. Yanlış pozitif (false positive) oranının düşük tutulması gereken senaryolarda önemli oldu. Örneğin, bir kişinin maskeli olduğunu tahmin eden modelin, gerçekten maskeli kişileri işaretlemesi beklendi. Aksi halde, maskesiz bireylerin gözden kaçması riski ortaya çıktı.

**Formül:**

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}}$$

2. Recall (Duyarlılık): Recall, modelin gerçekten pozitif olan örneklerin ne kadarını doğru tahmin ettiğini gösterdi. Bu metrik, özellikle negatif sonuçların ciddi sonuçlar doğurduğu uygulamalarda kritik öneme sahipti. Örneğin, maske takmayan bireylerin gözden kaçırılmaması gereken bir sistemde yüksek recall değeri hedeflendi.

**Formül:**

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}}$$

3. F1-Score: Precision ve recall, birbirine zıt durumları optimize ettiği için, bunların dengeli bir ortalaması olan F1-score, genel performansı daha tutarlı bir şekilde değerlendirmek amacıyla kullanıldı. Yüksek F1-score, modelin hem doğru tespitler yaptığını hem de çok fazla örneği kaçırmadığını gösterdi.

**Formül:**

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Bu metrik, özellikle negatif sonuçların ciddi sonuçlar doğurduğu uygulamalarda kritik öneme sahipti. Örneğin, maske takmayan bireylerin gözden kaçırılmaması gereken bir sistemde yüksek recall değeri hedeflendi.

Bu çalışmada kullanılan modeller, eğitim ve test verileri üzerinde doğruluk oranlarının yanı sıra precision, recall ve F1-score değerleriyle de değerlendirildi. Özellikle maske takmayan bireylerin doğru şekilde tespit edilmesi kritik olduğundan, recall metriği ön plana çıktı. Bununla birlikte, yanlış pozitifleri azaltmak amacıyla precision değerinin de yüksek tutulması hedeflendi. F1-score ise bu iki metriği dengeleyerek modelin genel başarımını yansıttı.

Farklı derinlikteki ResNet mimarileri (ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152), hem ön eğitilmiş hem de sıfırdan (scratch) eğitilerek karşılaştırıldı. Aşağıdaki örnek tabloda, yalnızca ön eğitilmiş modellerin test sonuçları sunuldu:

**Çizelge 3.1: Farklı Ağ Mimarilerinin ImageNet (ILSVRC) Üzerindeki Top-1 ve Top-5 Hata Oranları (%)**

Yöntem	Top-1 Hata (%)	Top-5 Hata (%)
VGG [40] (ILSVRC'14)	-	Ağu.43
GoogLeNet [43]	-	Tem.89
VGG [40] (v5)	24.Nis	7.Oca
PReLU-net [12]	21.59	May.71
BN-inception [16]	21.99	May.81
ResNet-34 B	21.84	May.71
ResNet-34 C	21.53	May.60
ResNet-50	20.74	May.25
ResNet-101	19.87	Nis.60
<b>ResNet-152</b>	<b>19.38</b>	<b>Nis.49</b>

Model seçiminde yalnızca doğruluk oranına odaklanmak, uygulamada gerçek zamanlılık gerektiren sistemler için yetersiz kaldı. Bu nedenle, hız ve performans birlikte değerlendirildi. Yapılan analizler sonucunda, ResNet-50 modeli hem doğruluk hem de çıkarım (inference) hızı açısından en dengeli çözüm olarak öne çıktı. ResNet-18, daha hızlı çalışmasına rağmen doğruluk oranı düşük kaldı. Öte yandan, ResNet-152 gibi daha derin modellerin doğruluğu çok az artarken işlem süresi ciddi oranda yükseldi.

### 3.1.10 Hiperparametre ayarlamaları ve eğitim stratejisi

Modelin genel başarımını artırmak ve en uygun yapılandırmayı elde edebilmek amacıyla çeşitli hiperparametre ayarlamaları yapıldı. Bu süreçte, modelin eğitim performansını doğrudan etkileyen öğrenme oranı, batch size (mini yığın boyutu), epoch sayısı, optimizier seçimi ve dropout oranı gibi hiperparametreler sistematik şekilde test edildi.

#### a. Öğrenme Oranı (Learning Rate):

Öğrenme oranı, modelin ağırlıklarını ne kadar büyük adımlarla güncellediğini belirler. Çok yüksek seçildiğinde model kararsız hâle gelirken, çok düşük olduğunda öğrenme süreci yavaşladı ve yerel minimumda takılı kaldı. Bu nedenle, başlangıçta farklı öğrenme oranları (örneğin 0.1, 0.01, 0.001) denendi ve doğruluk üzerindeki etkileri karşılaştırıldı. En iyi sonuç genellikle 0.001 civarında elde edildi.

b. Epoch Sayısı:

Modelin kaç defa tüm eğitim verisi üzerinden geçtiğini belirleyen epoch değeri, aşırı öğrenme (overfitting) riskine karşı dikkatli bir şekilde belirlendi. Eğitim ve doğrulama kayıplarının eğrileri takip edildi ve erken durdurma (early stopping) mekanizmasıyla overfitting engellendi. Deneme-yanılma süreci sonucunda 20–30 epoch aralığında optimum doğruluk elde edildi.

c. Parti Boyutu (Batch Size):

Mini-batch boyutu, modelin eğitim sürecinde her adımda kaç örnek kullandığını ifade eder. 16, 32 ve 64 gibi farklı değerlerle eğitimler gerçekleştirildi. 32'lik batch size ile hem bellek kullanımı dengelendi hem de doğruluk istikrarlı hâle geldi.

d. Optimizasyon Algoritması:

Stokastik Gradient Descent (SGD) ve Adam optimizasyon algoritmaları karşılaştırıldı. Adam, adaptif öğrenme oranı ve momentum avantajı sayesinde daha hızlı ve kararlı bir şekilde sonuca ulaştı. Bu nedenle nihai modelde Adam kullanıldı.

e. Bırakma (Dropout):

Overfitting'i önlemek amacıyla, özellikle tam bağlantılı katmanlarda dropout tekniği uygulandı. %20 ve %50 gibi farklı dropout oranları denendi; %50 oranı ile genel başarımlarda belirgin bir iyileşme gözlemlendi.

f. Deneme Yapısı:

Her hiperparametre kombinasyonu için model, eğitim ve doğrulama setleri üzerinde test edildi; elde edilen doğruluk (accuracy), hassasiyet (precision) ve duyarlılık (recall) değerleri kaydedildi. Bu analizler sonucunda en iyi performans gösteren hiperparametre kombinasyonu seçildi. [10]

## 3.2 Yazılım Metodolojisi

### 3.2.1 Resnet


ResNet, 2015 senesinde Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından büyük oranda daha detaylı olan ağların eğitimi rahatlatıldığı için

“Deep Residual Learning for Image Recognition” yazısında anlatılan bir sinir ağı çeşitidir. ResNet’in kazanımlarından bahsetmek gerekirse:

Faster R-CNN’de VGG-16 katmanını ResNet-101 ile değiştirilmesi ile COCO nesne algılama veri kümesi için %28 iyileşme görüldüğü gözlemlendi.[26]

Derin evrimsel sinir ağları, görsel sınıflandırma problemlerinde kayda değer ilerlemelere yol açtı. Bu ağlar, görüntü tanıma ve sınıflandırma gibi görevlerde en gelişmiş teknolojilere dayanan başarılı sonuçlar sundu. Zaman içinde, daha karmaşık problemleri çözebilmek adına derin öğrenme mimarileri daha fazla katman içerecek şekilde genişletildi ve bu ağlar giderek daha derin bir yapıya büründü. Bu gelişim, sınıflandırma ve tanıma performansında belirgin iyileşmelere ve bu görevlerin daha hassas bir şekilde yerine getirilmesine olanak sağladı.

Bununla birlikte, ağ derinliğinin artırılmasının performansı her zaman pozitif yönde etkileyip etkilemediği sorgulandı. Daha fazla katmana sahip bir ağın, her durumda daha düşük bir hata oranı sunup sunamayacağı araştırıldı. Bu soruları yanıtlayabilmek amacıyla, 20 katmanlı bir ağ ile 56 katmanlı bir ağın eğitim ve test hata oranlarını karşılaştıran aşağıdaki grafik incelendi. Grafik, ağ derinliği ile performans arasındaki ilişkinin dinamiklerini anlamak açısından önemli ipuçları sundu.




**Şekil 3.1: Orijinal Görüntü için Derin Artık Öğrenme [35]**

Soldaki grafik, eğitim hatalarını; sağdaki grafik ise test hatalarını gösterdi. Görüldüğü üzere, 56 katmanlı ağın eğitim ve test verileri için hata oranları, 20 katmanlı bir ağa kıyasla daha yüksek çıktı. Bu durum, bir sinir ağına daha fazla katman eklenmesinin performans üzerinde olumsuz bir etki yarattığını ortaya koydu.

Teorik olarak, ağ derinliği arttıkça eğitim hatalarının azalması beklendi. Ancak pratikte, belirli bir noktada doğruluk seviyesi doygunluğa ulaştı ve ardından eğitim hatasında hızlı bir artış gözlemlendi. Bu artış, genellikle aşırı öğrenme (overfitting) ile ilişkilendirilse de, bu durumda temel nedenin daha derin modellerin optimizasyonunun giderek zorlaşması olduğu belirlendi. Bu fenomen, bozulma (degradation) ya da optimizasyon sorunu olarak adlandırıldı ve derin ağlarda performans düşüşüne yol açtı.

X katman girdisinin toplanmasını sağlayan düz çizgi yapısı, **artık bağlanma** (residual connection) ya da **kısayol bağlanma** (shortcut connection) olarak tanımlandı. Artık bağlantılar, birden çok katmanı atlayarak ilerleyen bağlantılar şeklinde yapılandırıldı. Bu kısa yol blokları sayesinde, girdiler katmanlar arasında bulunan geçişleri daha verimli bir şekilde geçti ve derin ağların eğitim süreci daha kararlı hale getirildi.



Şekil 3.2: Artık Bloklar [30]

Artık bağlantı kullanmaksızın ilk olarak 'x' girdisi katmanın ağırlıkları ile çarpılma işlemi yapılır ve bir ön yargı terimi eklenmiş olur. Daha sonra  $f(x)$  aktivasyon fonksiyonundan geçmesi ile çıktı  $H(x)$  şeklinde alınacaktır.

$$H(x)=f( wx + b ) \text{ veya } H(x)=f(x)$$

Artık bağlantıyla birlikte çıktı;

$H(x) = f(x) + x$  olarak deęişiklikle göstermektedir.

### 3.3 Sonular

ImageNet 2012 sınıflandırma veri seti üzerinde uygulanan ResNet'in düz aę modeli (Plain Network) ile artık aę modeli (Residual Network) tarafından elde edilen sonuçlar karşılaştırmalı olarak incelendi. Bu veri seti, toplamda 1.000 sınıf içerdii için tercih edildi. Modeller, 1,28 milyon eğitim görseli ile eğitildi ve 50 bin doğrulama görseli üzerinden deęerlendirildi.

Bu karşılaştırma, düz aę modeli ile artık aę modelinin performans farkının analiz edilmesini ve derinlik artışının etkilerinin daha net bir şekilde ortaya konulmasını sağladı. ResNet'in sunduęu yenilikçi artık öğrenme (residual learning) mekanizmasının, modelin eğitim süreci üzerindeki olumlu etkisi ve test verisindeki doğruluęu nasıl geliştirdiđi bu bağlamda deęerlendirildi.

**izelge 3.2: Plain ve Resnet (%)**

Katman Sayısı	Plain	ResNet
18 katman	27.94	27.88
34 katman	28.54	<b>25.Mar</b>

Daha derin bir aę yapısının doğrulama hatasını azaltacađı yönündeki beklenti, 34 katman içeren düz aę ile 18 katman içeren düz aę arasında yapılan karşılaştırmada çelişkili sonuçlar ortaya koydu. 34 katmanlı düz aęın, daha sığ bir yapı olan 18 katmanlı düz aęa kıyasla daha fazla doğrulama hatası ürettiđi gözlemlendi. Bu durum, derin aęların doğruluk performansındaki bozulma (degradation) problemini açıka ortaya koydu. Teorik olarak daha fazla katman içeren bir düz aęın daha fazla özelliđi öğrenebilmesi beklenirken, pratikte daha yüksek eğitim hatası verdiđi görüldü.


Bu olgu, düz aęlarda katmanlar arasına atlama bağlantıları (skip connections) eklenmediğinde ortaya çıktı. Atlama bağlantılarının bulunmaması, derin aęların optimizasyonunu daha karmaşık hale getirdi ve hataların birikmesine yol açarak aę performansını düşürdü.

Bu kez, aynı derinlikteki artık aę bağlantısı modelleri incelendiğinde, 18 katmanlı ve 34 katmanlı artık aęların, düz aęlarla aynı temel mimariyi kullanmalarına rağmen, her 3×3 filtre çiftine artık bağlantılar (residual connections)

eklenerek oluşturulduğu görüldü. Bu artık bağlantılar, her bir katmanın girdisini çıktıya ekleyen bir yol sağladı.

Tüm kısa yol bağlantıları, doğrudan kimlik eşleştirme (identity mapping) yöntemi kullanılarak uygulandı. Daha yüksek boyutlu çıktılar için ise ek bir dolgu ya da fazladan parametre kullanılmadı.

Bu tasarım, parametre artışı olmaksızın hem eğitimi hem de doğruluğu iyileştirir. Atlama bağlantıları sayesinde derin ağların optimize edilebilirliği artırılmış olup, bozulma problemi önemli ölçüde giderildi. [21]



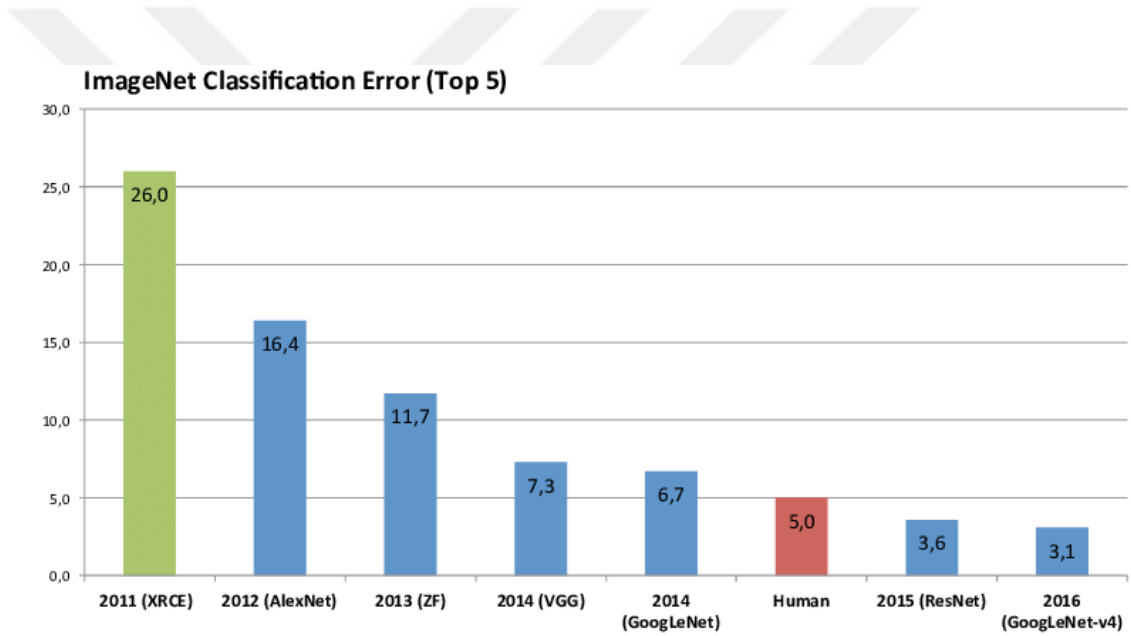
**Şekil 3.3: Plain ve Resnet Grafik [30]**

Bu bölümde üç temel gözlem öne çıktı. İlk olarak, artık öğrenme (residual learning) yaklaşımı sayesinde derinliğin olumsuz etkisi tersine çevrildi. Örneğin, 34 katmanlı bir ResNet mimarisinin, 18 katmanlı versiyonuna kıyasla yaklaşık %2,8 oranında daha yüksek doğruluk elde ettiği gözlemlendi. Daha da önemlisi, 34 katmanlı ağ daha düşük eğitim hatası sergiledi ve doğrulama verileri üzerinde daha güçlü genelleme performansı gösterdi. Bu durum, derinliğin neden olduğu bozulma probleminin etkili bir şekilde çözüldüğünü ve artan ağ derinliğinin doğruluk üzerinde olumlu katkılar sağladığını ortaya koydu. [14]

İkinci olarak, görece az katman içeren (örneğin 3–4 katmanlı) bir ResNet yapısının dahi, düz (plain) yapılara göre eğitim hatasını daha etkili biçimde azalttığı gözlemlendi. Bu iyileşme, özellikle Top-1 error oranında yaklaşık %3,5’lik bir düşüşle somutlaştı. Bu bulgular, artık öğrenme temelli mimarilerin ağ derinliği arttıkça performans kaybı yerine performans kazanımı sağlayabildiğini ve bu yaklaşımın öğrenme sürecinde kalıcı etkiler yarattığını doğruladı. [14]

**Çizelge 3.3: Resnet Method Hata Verileri (%)**

Yöntem	Top-1 Hata (%)	Top-5 Hata (%)
VGG [40] (ILSVRC'14)	-	Ağu.43
GoogLeNet [43]	-	Tem.89
VGG [40] (v5)	24.Nis	7.Oca
PReLU-net [12]	21.59	May.71
BN-inception [16]	21.99	May.81
ResNet-34 B	21.84	May.71
ResNet-34 C	21.53	May.60
ResNet-50	20.74	May.25
ResNet-101	19.87	Nis.60
<b>ResNet-152</b>	<b>19.38</b>	<b>Nis.49</b>



**Şekil 3.4: Yıllara göre Sınıflandırma Hataları [30]**

Neticede, ResNet mimarisinin, kısayol bağlantıları sayesinde birkaç katmanı atlayarak daha derin bir ağ ile optimizasyon ve bozulma sorunlarının üstesinden gelmeyi başardığı ve böylece derin ağların performansını önemli ölçüde artırdığı anlaşıldı. Bu yöntem, derinlikten kaynaklanan doğruluk düşüşlerini engelleyerek derin modellerin pratik kullanımını mümkün hâle getirdi. [11]

ResNet-50, 34 katmanlı düz ağ mimarisindeki her iki katmanlı bloğun, üç katman içeren **darboğaz blokları** (*bottleneck blocks*) ile değiştirilmesi sonucu elde edildi. Her artık fonksiyon FFF, iki yerine üç katman içeren bir yığın olarak yapılandırıldı. Bu bloklar:

1×1 konvolüsyonlar: Giriş boyutlarını azaltma ve sonrasında geri yükleme (boyut artırma) görevini üstlenir.

3×3 konvolüsyonlar: Daha az giriş/çıkış boyutuyla darboğaz görevi görür.

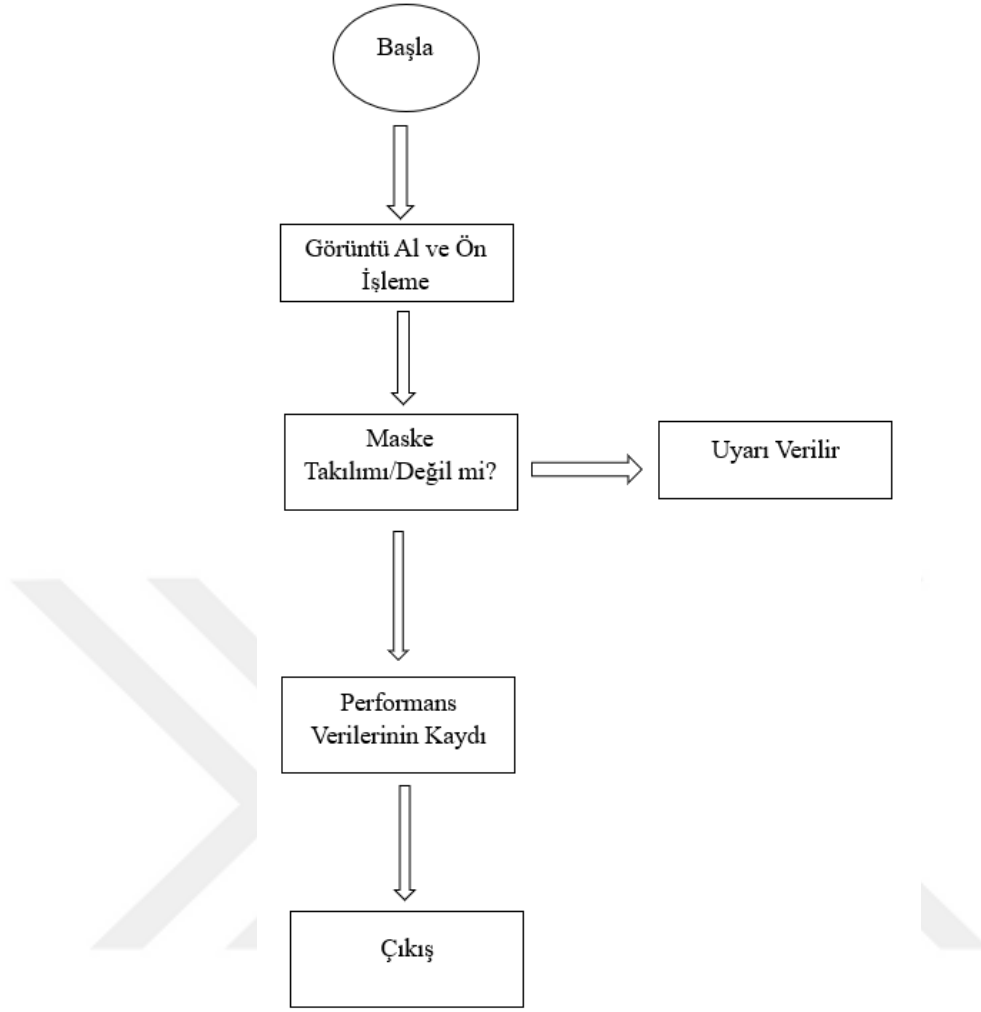
Bu yapılandırma hem parametre verimliliği sağlar, hem de daha derin mimarilerde doğruluk kaybını minimize eder.

ResNet-101 ve ResNet-152 gibi daha derin ResNet modelleri, daha fazla üç katmanlı blok kullanılarak oluşturuldu ve sırasıyla 101 ile 152 katman içerdi. Bu modeller, daha derin olmalarına rağmen, 34 katmanlı ağlara kıyasla daha yüksek doğruluk oranları sundu.

Katman sayısının artırılmasıyla birlikte, ResNet'in artık ağ yapısı bozulma (degradation) problemini büyük ölçüde çözdü ve derinlikten kaynaklanan doğruluk kazanımlarını güvenli bir şekilde sağladı. ResNet, kısayol bağlantıları sayesinde birkaç katmanı atlayabilen bir yapı sundu. Bu özellik, daha derin ağların optimizasyon sorunlarının aşılmasını sağladı, derinliğe bağlı doğruluk kazanımlarını artırdı ve genel performans artışına katkıda bulundu. Tüm bu unsurlar, ResNet'in derin öğrenme modelleri arasında hem akademik araştırmalarda hem de endüstriyel uygulamalarda bir standart haline gelmesine olanak tanıdı.

### **3.4 Sistem Gereksinimleri**

Yazılım olarak Python'a, donanım olarak ise bir bilgisayar ve kameraya ihtiyaç duyuldu.



**Şekil 3.5: Sistemin Akış Diyagramı**

Bu çalışmada, hastane gibi enfeksiyon kontrolünün kritik olduğu ortamlarda yüz maskesi tespiti için derin öğrenme tabanlı bir sistem geliştirildi. Bu sistemin farklı donanım platformlarındaki (CPU ve GPU) performansı detaylı bir şekilde incelendi. Yapılan analizler, gerçek zamanlı maske tespiti teknolojisinin hastanelerde enfeksiyon kontrolüne katkı sağlamak için önemli bir araç olduğunu ve doğru donanım ile model konfigürasyonları kullanıldığında kayda değer performans iyileştirmelerinin elde edilebileceğini ortaya koydu.

- a. **Model Performansı:** ResNet ailesinin çeşitli varyantları, yüz maskesi tespiti görevinde yüksek doğruluk ve güçlü genel performans sergileyerek, derin öğrenme tabanlı sistemin maskelerin doğru kullanımını tespit etme konusundaki etkinliği kanıtladı. ResNet-50 ve ResNet-101 gibi daha derin modeller, yüksek doğruluk oranları ile hassas alanlarda (ameliyathane gibi)

en iyi performansı sunarken, daha hafif modeller (ResNet-18) ise hız gerektiren alanlarda (bekleme salonları gibi) daha uygun olduğu anlaşıldı.

- b. **Donanım Performansı:** CPU ve GPU arasındaki karşılaştırmalar, her iki donanımın avantaj ve dezavantajlarını ortaya koydu. CPU; düşük maliyetli ve yaygın erişilebilir bir seçenek olarak, düşük doğruluk gereksinimi ve hız önceliği taşıyan ortamlarda (örneğin, bekleme salonları) etkili olduğu görüldü. GPU ise, paralel işlem gücü sayesinde büyük modelleri daha hızlı işleyerek, yüksek doğruluk gerektiren ameliyathane gibi kritik ortamlarda daha üstün performans sergiledi. Bu durum, donanım seçiminde hız ve doğruluk gereksinimlerinin dikkatlice değerlendirilmesinin önemini vurguladı.
- c. **Optimum Yapılandırmalar:** Farklı hastane ortamlarında (ameliyathane, bekleme salonu vb.) yapılan testler, her bir ortam için farklı model ve donanım yapılandırmalarının en verimli sonucu verdiğini gösterdi. Yüksek doğruluk gerektiren ortamlarda daha derin ve güçlü modeller tercih edilirken, yoğun kullanıcı trafiği olan, hız öncelikli alanlarda daha hafif ve hızlı modellerin tercih edildiği gözlemlendi.
- d. **Hız-Doğruluk-Maliyet Dengesi:** Çalışma, hız, doğruluk ve maliyet arasındaki dengeyi optimize ederek hastane içindeki farklı kullanım senaryoları için en uygun yapılandırmaların belirlenmesini sağladı. GPU ile yüksek doğruluk elde edilirken, CPU ile daha düşük maliyetli ancak yeterli performans sunan çözümler elde edildi.

Sonuç olarak, bu tez çalışmasında hastane ortamlarında maskeli yüz tespit sistemlerinin uygulanabilirliğini artırmak ve gerçek zamanlı maskeli yüz tespiti teknolojisinin hız, doğruluk ve maliyet açısından nasıl optimize edilebileceğine dair önemli öngörüler sağlandı. Geliştirilen sistem, özellikle enfeksiyon kontrolü açısından hastaneler gibi kritik alanlarda maske kullanımını izleyerek bulaşma riskini azaltmak adına değerli bir çözüm sundu.

Çalışmanın bulguları, derin öğrenme tabanlı tespit sistemlerinin sağlık sektöründe — özellikle enfeksiyon kontrolü alanında — daha geniş bir uygulama yelpazesi bulmasına olanak sağladı. Bu tez, yalnızca hastane ortamlarında değil;

havaalanları, otobüs durakları gibi toplu kullanım alanlarında da maskeli yüz tespiti teknolojisinin etkin bir şekilde kullanılmasına dair rehberlik edici bir kaynak sundu.

Gelecekte yapılacak çalışmaların, daha büyük veri setleriyle test edilen modeller aracılığıyla doğruluk oranlarını daha da artırabileceği ve hız optimizasyonlarını geliştirebileceği öngörüldü.

### 3.5 Hız Testi

Alttaaki verilerde de saniyedeki tarama hızları (frame per sechond) rakamsal değerlerle gösterildi.

**Çizelge 3.4: Freme per sechond (Saniye Başına Düşen Görsel)**

Device	The concentration of FRP (frame per sechond)				
	R18	R34	R50	R101	R152
GPU	109.105	59.959	50.546	28.829	21.277
CPU	42.232	27.348	10.597	6.141	4.207

Bu FPS (frame per second) değerleri göz önünde bulundurulduğunda, hız testi sonuçları şu şekilde yorumlandı:

#### a. GPU Performansı:

ResNet18 (r18) modeli GPU üzerinde en yüksek FPS değerini sunmaktadır: 109.105 FPS. Bu da, GPU'nun derin öğrenme görevleri için ne kadar verimli çalıştığını ortaya koydu. ResNet34 (r34) ve ResNet50 (r50) modelleri sırasıyla 59.959 FPS ve 50.546 FPS ile GPU üzerinde yüksek hızlar sağladı. Ancak ResNet101 (r101) ve ResNet152 (r152) gibi sırasıyla 28.829 FPS ve 21.277 FPS daha derin modellerde FPS değeri oldukça düştüğü gözlemlendi. Bu durum, derin modellerin daha fazla hesaplama gücü gerektirdiğini ve bu nedenle hızın düştüğünü gösterdi.

#### b. CPU Performansı:

CPU üzerinde FPS değerleri, GPU ile karşılaştırıldığında belirgin şekilde daha düşük olduğu gözlenmektedir. ResNet18 (r18) modeli 42.232 FPS ile CPU üzerinde makul bir hız sağlasa da, daha derin modellerde bu hızlar önemli ölçüde düştüğü görüldü. Örneğin, ResNet34 (r34) modelinde 27.348 FPS, ResNet50 (r50) modelinde 10.597 FPS ve ResNet101 (r101) modelinde 6.141 FPS elde edilmektedir. ResNet152 (r152) ile ise FPS değeri sadece 4.207'ye düştüğü anlaşıldı.

### c. Hız Testi Sonucu ve Yorum:

GPU'nun Genel Üstünlüğü:

GPU, özellikle daha derin ve hesaplama yoğun modellerde hız açısından belirgin bir avantaj sağladı. Özellikle ResNet18 modelinin GPU üzerindeki FPS değeri 109.105 olarak ölçüldü ve CPU'ya göre çok daha yüksek bir performans sunduğu gözlemlendi.

CPU'nun Sınırlamaları:

CPU üzerinde yapılan testler, hız açısından GPU'ya kıyasla önemli ölçüde daha yavaş sonuçlar verdi. Bu durumun, CPU'nun paralel işlem yeteneklerinin GPU kadar güçlü olmamasından kaynaklandığı anlaşıldı.

Model Derinliğinin Etkisi:

Daha derin modeller (ResNet101, ResNet152), hem CPU hem de GPU üzerinde daha düşük FPS değerleri gösterdi. Bu bulgu, derin modellerin daha fazla hesaplama gücü ve bellek gerektirmesi nedeniyle hızın düştüğünü ortaya koydu.

Bu hız testleri sonucunda, GPU'nun daha hızlı sonuçlar sunduğu ve özellikle yüksek doğruluk gerektiren ancak aynı zamanda hızın da kritik olduğu görevlerde daha uygun bir donanım seçeneği olduğu belirlendi. CPU ise daha düşük maliyetli olmakla birlikte, hız açısından sınırlı kaldı.

CPU ile daha hafif modeller (ResNet18, ResNet34) kullanılarak, yüksek hız gerektiren ancak doğruluğun görece daha az kritik olduğu bekleme salonu gibi alanlarda yeterli performans elde edildi. Öte yandan, GPU ile derin modeller (ResNet50 ve üzeri) kullanıldığında, yüksek doğruluk ve hız gerektiren ameliyathane gibi hassas ortamlarda daha üstün performans sağlandığı görüldü. GPU, derin ResNet modellerinin yüksek hesaplama gereksinimlerini karşılayarak hem doğruluk hem de hız açısından önemli avantajlar sundu. [1,2,3]

### 3.6 Eğitim Verisi Öğrenme Grafiği

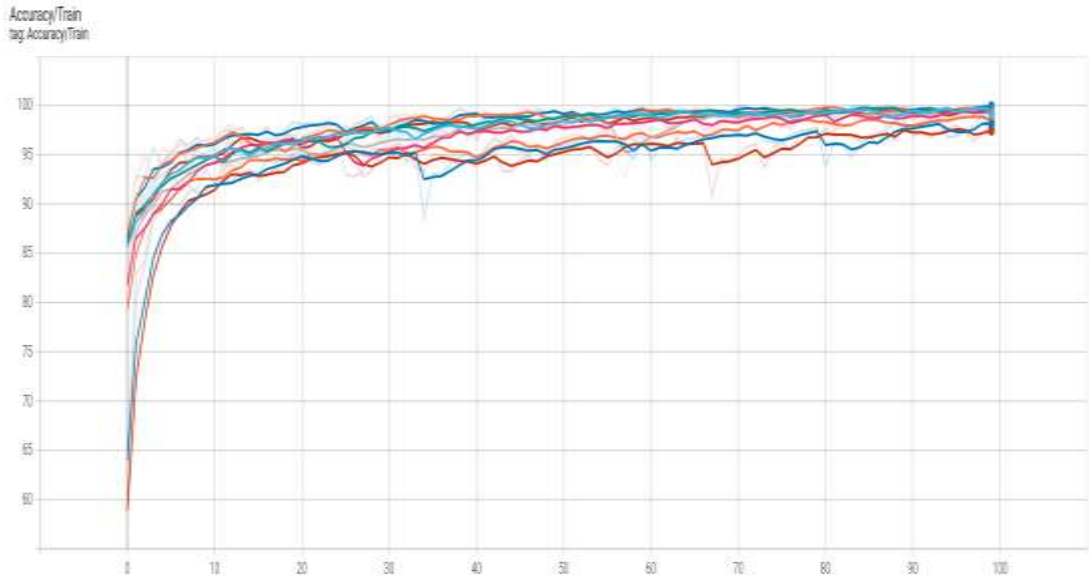
Eğitim doğruluğu, bir makine öğrenme modelinin eğitim verileri üzerinde ne kadar doğru sonuçlar verdiğini gösteren ölçülebilir bir metriktir. Eğitim verileri, modelin öğrenme süreci boyunca hedef problemi çözebilmesi amacıyla kullanılan örnek değerleri içermektedir.

Bu tez çalışmasında kullanılan model, genellikle maskeli ve maskesiz yüzleri sınıflandırmada, doğru olarak sınıflandırdığı örneklerin yüzde değerini hesapladı. Aşağıda verilen test doğruluğu grafiğinde görüldüğü üzere başarı oranı zamanla arttı; bu durum, modelin test verileri üzerinde daha yüksek doğruluk elde ettiğini ve genelleme yeteneğinin geliştiğini gösterdi.

Deneysel öğrenme sürecinin bir parçası olarak, farklı model yapıları ile birlikte çeşitli parametre ve hiperparametre değerleri (epoch sayısı, öğrenme oranı, mini batch boyutu) denenerek en başarılı sonuçların elde edilmesi hedeflendi. Bu tekrarlamalı işlemler, modelin performansını optimize etmek amacıyla gerçekleştirildi.

Buna ek olarak, modelin eğitimi için kullanılan veri setinin kalitesi ve miktarı da önemli bir rol oynadı. Daha fazla ve daha temsil edici verilerin kullanılması, modelin daha iyi öğrenmesini ve performans değerlerinin artmasını sağladı.

Son olarak, eğitim doğruluğu grafiği, modelin eğitim verileri üzerindeki doğruluk-zaman ilişkisini ortaya koydu. Grafikteki doğruluk değerinin zamanla artması, modelin eğitim sürecinde başarıyla öğrenmeye devam ettiğini gösterdi.



**Şekil 3.6: Eğitim Doğruluğu Test Grafiği**

Name	Smoothed	Value	Step	Time	Relative
r101_PretrainedFalse_Size64	98.11	98.11	99	Fri Apr 1, 01:43:39	14m 54s
r101_PretrainedTrue_Size64	98.6	98.6	99	Fri Apr 1, 00:42:22	15m 9s
r152_PretrainedFalse_Size64	97.9	97.9	99	Fri Apr 1, 02:03:45	19m 53s
r152_PretrainedTrue_Size64	99.37	99.37	99	Fri Apr 1, 01:02:19	19m 43s
r18_PretrainedFalse_Size64	99.58	99.58	99	Fri Apr 1, 01:09:30	7m 6s
r18_PretrainedTrue_Size64	99.58	99.58	99	Fri Apr 1, 00:06:00	7m 9s
r34_PretrainedFalse_Size64	99.93	99.93	99	Fri Apr 1, 01:18:23	8m 46s
r34_PretrainedTrue_Size64	100	100	99	Fri Apr 1, 00:15:48	9m 42s
r50_PretrainedFalse_Size64	98.04	98.04	99	Fri Apr 1, 01:28:35	10m 5s
r50_PretrainedTrue_Size64	99.65	99.65	99	Fri Apr 1, 00:27:03	11m 7s

**Şekil 3.7: Eğitim Değerlerine Göre Doğruluk Oranları**

Bu tez çalışması kapsamında geliştirilen eğitim doğruluğu grafiği, derin öğrenme tabanlı maske tespiti sisteminin eğitim performansını ve genel başarısını değerlendirmek amacıyla önemli bir analiz aracı olarak kullanılmaktadır. Bu grafikte aşağıdaki durumlar bilhassa incelendi:

- ResNet-101 (r101\_ Önceden Eğitilmemiş (Pretrainedfalse):** Pürüzsüzleştirme (Smoothed) 98.11 vs r101\_ Önceden Eğitilmiş (Pretrainedtrue): Pürüzsüzleştirme 98.6) ResNet-101 modelinde, önceden eğitilmiş (pretrained) model Pürüzsüzleştirme düzeltilme doğruluk 98.6'ya yükseldiği anlaşıldı. Fakat önceden eğitilmemiş modelde (r101\_ Önceden Eğitilmemiş) pürüzsüzleştirme doğruluk değeri 98.11 olarak ölçüldü. Bu durum, önceden eğitilmiş modelin daha hızlı ve verimli bir şekilde optimize edilebildiğini ve genel doğruluğu arttırdığını gösterdi. Önceden eğitilmiş model, daha fazla özellik öğrenerek, modelin daha sağlam bir şekilde eğitilmesini sağlayabileceği şeklinde yorumlandı.
- ResNet-152 (r152\_false: Pürüzsüzleştirme 97.9 vs r152\_true: Pürüzsüzleştirme 99.37)** ResNet-152 modelinde de önceden eğitilmiş model (r152\_true) ile önemli bir performans artışı sağladı. Önceden eğitilmiş modelin pürüzsüzleştirme doğruluğu 99.37'ye yükselirken, eğitilmemiş modelde bu değer 97,9 olarak kaldığı anlaşıldı. Bu, derin öğrenme modellerinde önceden eğitim almanın modelin optimizasyonu üzerinde büyük bir katkı sağladığını ve doğruluk oranlarını önemli ölçüde arttırdığını gösterdi. Derin modellerin daha fazla özellik öğrenebilmesi ve eğitim sürecinde daha

iyi genelleme yapabilmesi için önceden eğitilmiş ağırlıkların önemli bir rol oynadığı söylenebilir.

- c. **ResNet-18 (r18\_false: Pürüzsüzleştirme 99.58 vs r18\_true: Pürüzsüzleştirme 99.58)**. ResNet-18 modelinde ise önceden eğitilmiş (r18\_true) ve önceden eğitilmemiş (r18\_false) modellerin pürüzsüzleştirme doğruluk değerleri aynıdır (99.58). Bu, daha küçük ve daha sık modellerin, önceden eğitilmiş ağırlıklardan bağımsız olarak zaten yüksek doğruluk seviyelerine ulaşabildiğini ve önceden eğitilmiş model kullanımının bu modeller için ekstra bir fayda sağlamadığını gösterdi. Küçük modellerin daha az parametreye sahip olması, onların hızlı ve etkin bir şekilde eğitilebilmesini sağlar.
- d. **ResNet-34 (r34\_false: Pürüzsüzleştirme 99.33 vs r34\_true: Pürüzsüzleştirme 100)**. ResNet-34 modelinde önceden eğitilmiş model (r34\_true) belirgin bir iyileşme gösterdiği anlaşıldı. Pürüzsüzleştirme doğruluk 99.33'ten 100'e yükseldiği anlaşılmış olup, bu durum, önceden eğitilmiş modelin genelleme yeteneğini iyileştirerek daha yüksek doğruluk elde edilmesini sağladığını gösterir. Daha derin modellerde önceden eğitilmiş ağırlıklar, modelin hızlı ve verimli bir şekilde öğrenmesini sağlayabilir.
- e. **ResNet-50 (r50\_false: Pürüzsüzleştirme 98.04 vs r50\_true: Pürüzsüzleştirme 99.65)**. ResNet-50 modelinde de önceden eğitilmiş modelin kullanılması (r50\_true) pürüzsüzleştirme doğrulukta belirgin bir artışa yol açmaktadır. Önceden eğitilmemiş modelde pürüzsüzleştirme doğruluk 98.04 iken, önceden eğitilmiş modelde bu değer 99.65'e çıktı. Bu durum, önceden eğitilmiş modellerin daha hızlı optimize edilmesini ve daha iyi genelleme yapmasını sağladığını, özellikle büyük ve derin modellerde doğruluk artışı sağladığını gösterdi.

Yapılan değerlendirmelere göre, ResNet-34 (önceden eğitilmiş) modeli, hem hızlı öğrenme süreci hem de yüksek doğruluk açısından en iyi performansı gösterdi. Bu model, düşük derinliği ve önceden eğitilmiş ağırlıkları sayesinde %100 doğrulukla hızlı ve etkili bir öğrenme süreci sundu.

ResNet-50 ve ResNet-152, önceden eğitilmiş ağırlıklar kullanıldığında en fazla doğruluk kazancı sağlayan modeller olurken; ResNet-18, önceden eğitilmiş

ağırlıklara ihtiyaç duymaksızın da etkili bir şekilde öğrenebilen model olarak öne çıktı.

CPU ve GPU platformlarında farklı model performanslarının grafik üzerindeki etkisi değerlendirildiğinde, GPU'nun paralel işlem gücü sayesinde eğitim sürecinin daha hızlı tamamlandığı ve bunun da doğruluk eğrisinde daha hızlı bir artışa neden olduğu gözlemlendi.

Gerçek zamanlı kullanım senaryolarında, doğruluk gereksinimlerine göre hangi modelin optimum sonuç verdiği; modelin hem eğitim süresi hem de ulaştığı maksimum doğruluk değeri dikkate alınarak belirlendi. Bu kapsamda yapılan analizlere göre:

ResNet-34 (önceden eğitilmiş) modeli, %100 doğruluk oranına ulaşması ve orta düzeyde derinliği sayesinde hızlı ve verimli bir eğitim süreci sundu. Bu yönüyle gerçek zamanlı yüz tanıma gibi uygulamalarda yüksek doğruluk ve düşük gecikme ihtiyacını başarıyla karşıladı.

Daha sade yapıya sahip ResNet-18, düşük kaynak tüketimi ile öne çıktı ve önceden eğitilmiş ağırlıklara ihtiyaç duymadan %99.58 doğruluk oranına ulaştı. Bu nedenle, mobil veya gömülü sistemlerde tercih edildi.

Öte yandan, ResNet-50, ResNet-101 ve ResNet-152 gibi daha derin modeller, özellikle önceden eğitilmiş olarak kullanıldığında yüksek doğruluk sağladı. Ancak bu modellerin yüksek hesaplama gereksinimleri ve uzun eğitim süreleri nedeniyle, daha çok arka plan analizleri ya da tıbbi görüntüleme gibi doğruluğun ön planda olduğu alanlarda tercih edildi.

Ayrıca, derin öğrenme modellerinin CPU ve GPU üzerindeki performans farkı da önemli bir değerlendirme kriteri olarak öne çıktı. GPU'nun paralel işlem yeteneği sayesinde, derin modellerin eğitim süresi kısaldı ve doğruluk eğrisi daha hızlı yükseldi. Bu bağlamda, kaynakların kısıtlı olduğu sistemlerde, CPU ile uyumlu daha az katmanlı modellerin tercih edilmesi gerektiği sonucuna varıldı.

Sonuç olarak, sistem gereksinimlerine ve uygulama senaryosuna bağlı olarak şu öneriler getirildi:

Gerçek zamanlı uygulamalarda: ResNet-34 en uygun modeldir.

Düşük donanım kaynaklı sistemlerde: ResNet-18 önerilmektedir.

Yüksek doğruluk gerektiren offline analizlerde: ResNet-50 ve üzeri modeller tercih edilmelidir.

Bu grafikten elde edilen veriler, hastane gibi kritik ortamlarda yüksek doğruluk gereksinimlerine uygun modeller ile, daha hızlı ancak daha düşük doğruluk gerektiren senaryolar için tercih edilen modellerin karşılaştırılmasında kullanıldı.

**a. Derin Modeller (ResNet-34, ResNet-152):**

Derin modellerde önceden eğitilmemiş ağırlıkların kullanımı, genellikle model performansında iyileşme sağladı. Ancak, her bir modelin kendine özgü mimarisi ve kullanılan veri setinin özellikleri göz önüne alındığında, bu iyileşmenin her zaman belirgin olmayabileceği görüldü. Özellikle ResNet-34 modelindeki belirgin doğruluk artışı, derin modellerin önceden eğitilmiş ağırlıklarla daha verimli bir şekilde optimize edilebildiğini ve genelleme yeteneklerinin arttığını ortaya koydu.

**b. Küçük Modeller (ResNet-18, ResNet-50):**

Daha küçük ve daha az parametreye sahip modellerde (örneğin, ResNet-18 ve ResNet-50), önceden eğitilmiş ağırlıkların etkisinin sınırlı kaldığı gözlemlendi. Özellikle ResNet-50 modelinde, önceden eğitilmiş ağırlıkların doğruluk üzerinde ek bir katkı sağlamadığı tespit edildi. Bu durum, küçük modellerin daha basit yapıları sayesinde, önceden eğitilmiş ağırlıklara ihtiyaç duymaksızın da yüksek doğruluk seviyelerine ulaşabildiğini ortaya koydu.

Sonuç olarak, önceden eğitilmiş modellerin genellikle daha derin ağlarda doğruluk ve genelleme yeteneklerini artırdığı; ancak bu etkinin, model mimarisi ve kullanılan veri setinin özelliklerine bağlı olarak değişiklik gösterebileceği sonucuna varıldı. Küçük modellerde ise önceden eğitilmiş ağırlıkların katkısının sınırlı kaldığı, buna karşılık bu modellerin daha hızlı ve verimli bir şekilde eğitilebildiği belirlendi. [1,3]

### 3.7 Doğruluk Testi Grafiği

Doğruluk testi, bir modelin gerçek dünya verileri üzerindeki performansını değerlendirmek amacıyla yaygın şekilde kullanılan bir ölçüt olup, modelin tahminlerinin gerçeğe ne derece yakın olduğunu ortaya koydu. Bu doğrultuda, eğitim ve test verileri üzerindeki doğruluk oranlarının birbirine yakın olması, modelin

yüksek genelleme yeteneğine sahip olduğunu gösterdi. Eğitim doğruluğu ile test doğruluğu arasındaki tutarlılık, modelin yalnızca eğitim verisini ezberlemediğini; aynı zamanda genel veri dağılımını öğrenerek daha önce görmediği veriler üzerinde de başarılı tahminlerde bulunabildiğini ortaya koydu. Aksi durumda, test doğruluğunun eğitim doğruluğuna kıyasla belirgin şekilde düşük kalması, modelin aşırı öğrenme (overfitting) eğilimi gösterdiğini ve yeni verilere karşı genelleme kabiliyetinin zayıf olduğunu işaret etti.

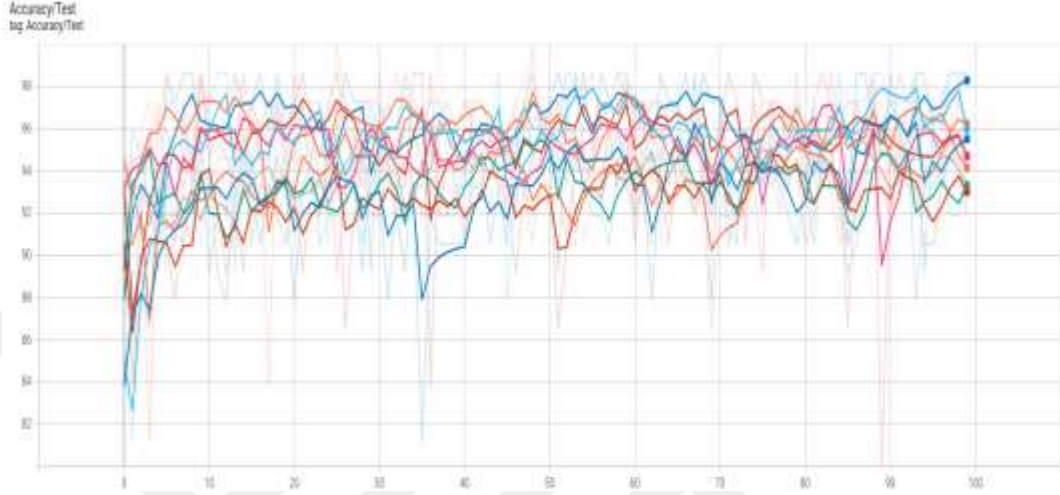
Eğitim ve test doğruluğu eğrilerinin benzer bir gelişim sergilemesi — örneğin, her iki eğrinin de zamanla artarak belirli bir plato seviyesine ulaşması — modelin dengeli ve etkili bir şekilde öğrenme gerçekleştirdiğini gösterdi. Ancak test doğruluğunda gözlemlenen dalgalanmalar veya test doğruluğunun eğitim doğruluğundan bağımsız seyretmesi, yetersiz öğrenme (underfitting) durumunu akla getirdi. Bu durum, modelin eğitim süreci boyunca veri setindeki anlamlı örüntüleri yeterince öğrenemediğine işaret etti.

Ayrıca, model performansı ile donanım arasındaki ilişki de dikkate alınması gereken önemli bir faktör olarak değerlendirildi. GPU gibi paralel işlem gücüne sahip donanımlar, modellerin daha hızlı optimize edilmesini sağladı ve bu durum, test doğruluğu eğrisinin daha erken plato yapmasıyla gözlemlendi. Öte yandan, kullanılan model mimarisinin derinliği de doğruluk oranlarını doğrudan etkileyen bir değişken oldu. Örneğin, ResNet-50 veya ResNet-101 gibi derin modeller, daha karmaşık veri yapılarında yüksek doğruluk sağlarken; ResNet-18 gibi daha hafif yapılar, daha düşük doğrulukla birlikte işlem hızı açısından avantaj sundu.

Bu nedenle, uygulama senaryosuna uygun model ve donanım seçimi, sistem performansı açısından kritik öneme sahip olduğu sonucuna varıldı. Eğitim ve test doğrulukları arasındaki fark, literatürde “genelleme boşluğu” olarak tanımlandı ve modelin gerçek dünyadaki veri üzerindeki başarımının önemli bir göstergesi olarak kabul edildi. Bu farkın düşük olması, modelin hem eğitim hem de test verisinde başarılı sonuçlar verdiğini gösterirken; farkın yüksek olması durumunda düzenlileştirici tekniklerin (örneğin, dropout veya weight decay) kullanım gerekliliği ortaya çıktı.

Son olarak, modelin eğitimi için kullanılan veri kümesinin kalitesi ve miktarının da model performansı üzerinde doğrudan etkili olduğu belirlendi. Yeterli

sayıda, çeşitliliğe sahip ve temsiliyeti yüksek verilerle eğitilen modellerin doğruluk testlerinde daha yüksek performans sergilediği deneysel olarak gözlemlendi. Bu bağlamda, test doğruluğu grafiklerinin incelenmesiyle modelin zamanla gelişim gösterdiği, genel doğruluk seviyesinin arttığı ve dolayısıyla genelleme kabiliyetinin iyileştiği sonucuna ulaşıldı.



**Şekil 3.8: Doğruluk Test Data Doğrulama Başarı Oranları**

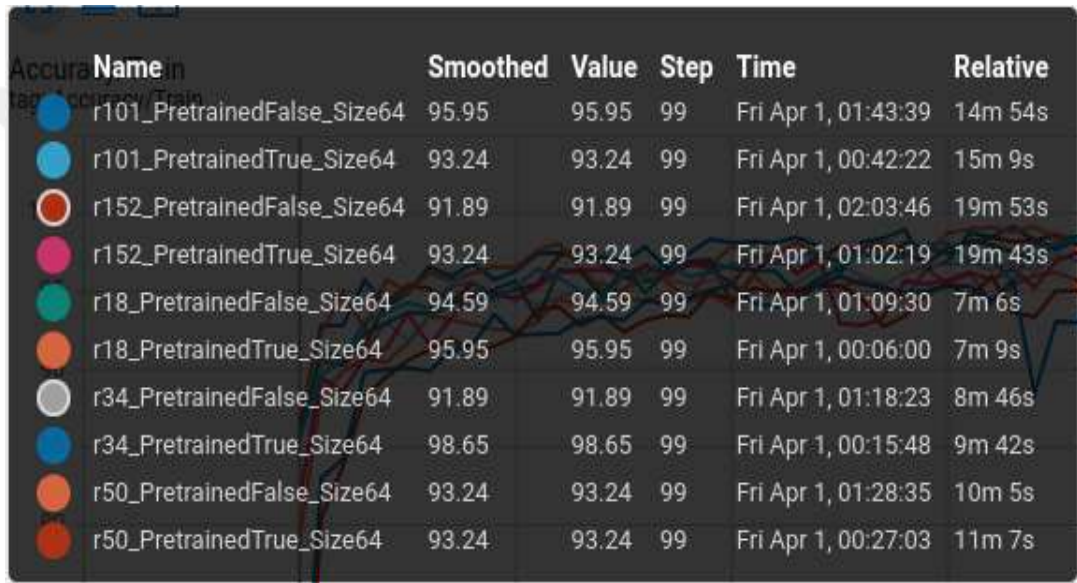
Hastane ortamlarında geliştirilen maske tespit sistemlerinin etkinliğini değerlendirmek amacıyla kullanılan doğruluk test grafikleri, sistemin gerçek dünya koşullarındaki performansını simüle etmek ve çeşitli kullanım senaryolarına uygunluğunu analiz etmek açısından kritik bir rol üstlendi. Bu grafikler, farklı hastane alanlarında hız ve doğruluk arasında kurulması gereken dengeyi görselleştirerek, model seçim sürecinde önemli bir karar destek aracı işlevi gördü.

Özellikle yüksek doğruluk gerektiren ameliyathane gibi steril ve kritik ortamlarda, derin yapıya sahip modellerin performans avantajı dikkat çekti. Bu kapsamda, ResNet-50 gibi daha karmaşık ve yüksek parametre sayısına sahip modellerin, test verileri üzerinde sağladığı yüksek doğruluk oranları sayesinde tercih edilebilirliği arttı. Bu tür ortamlarda doğruluk düzeyinin yüksek olması, enfeksiyon riskini azaltmak ve klinik güvenliği sağlamak açısından büyük önem taşıdı.

Öte yandan, hasta bekleme salonları gibi yoğun sirkülasyonun yaşandığı ve işlem hızının öncelikli olduğu alanlarda ise, daha hafif yapıya sahip modellerin kullanımı öne çıktı. ResNet-18 gibi daha az katmanlı ve hızlı çalışan modeller, test doğruluğu açısından çok küçük kayıplara rağmen, işlem hızında sağladıkları avantaj sayesinde bu tür ortamlarda yeterli performans sundu. Bu durum, hız ve doğruluk

arasındaki deęiş tokuşun kullanım senaryolarına göre nasıl optimize edilebileceğini ortaya koydu.

Sonuç olarak, doğruluk-test grafikleri, yalnızca modelin doğruluk oranlarının zaman içindeki deęişimini sunmakla kalmadı; aynı zamanda ilgili modelin belirli bir klinik senaryoya ne derece uygun olduğunu belirlemek için güçlü bir analiz zemini oluşturdu. Böylece geliştirilen maske tespit sisteminin, hastane ortamlarında hız, doğruluk ve donanım uyumluluęu açısından en uygun dengeyle uygulanması sağlandı; sistemin gerçek zamanlı ve etkili bir şekilde kullanılmasına yönelik optimize edilmiş çözümler geliştirilebildi.



Şekil 3.9: Test Data Doğrulama Başarı Oranları

Bu çalışmada kullanılan ResNet mimarileri — ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152 — ağların sahip olduğu katman sayısını ifade etmekte olup, bu farklı derinlikteki modeller performans karşılaştırması ve değerlendirme amacıyla analiz edildi.

**a. ResNet-101 (r101\_ Önceden Eğitilmemiş: Pürüzsüzleştirme 95.95 vs r101\_ Önceden Eğitilmiş: Pürüzsüzleştirme 93.24)**

ResNet-101 modelinde, önceden eğitilmiş model (r101\_Önceden Eğitilmiş) test doğruluğunda belirgin bir düşüş gösterdi. Önceden eğitilmiş modelin pürüzsüzleştirme doğruluęu 93.24 iken, eğitilmemiş modelde (r101\_ Önceden Eğitilmemiş) bu deęer 95.95'tir. Bu durum, önceden eğitilmiş modelin test verisi üzerinde daha kötü performans gösterdiğini ve modelin genelleme yeteneğini

olumsuz etkileyebileceğini gösterdi. Önceden eğitilmiş model, belki de eğitim verisi ile aşırı uyum sağlamış ve test verisine karşı aşırı uyum yapmış olabilir.

**b. ResNet-152 (r152\_ Önceden Eğitilmemiş: Pürüzsüzleştirme 91.89 vs r152\_ Önceden Eğitilmiş: Pürüzsüzleştirme 93.24)**

ResNet-152 modelinde ise, önceden eğitilmiş model (r152\_ Önceden Eğitilmiş) test doğruluğunda küçük bir artış sağladı. Önceden eğitilmiş modelin pürüzsüzleştirme doğruluğu 93.24'e çıkarken, eğitilmemiş modelde bu değer 91.89'dur. Bu, önceden eğitilmiş modelin test verisi üzerinde daha iyi genelleme yapabildiğini ve eğitim verisinin etkilerini daha uygun şekilde taşıdığını gösterdi. Bu sonuç, daha derin modellerde önceden eğitilmiş ağırlıkların faydalı olabileceğini ve modelin test doğruluğunu iyileştirebileceğini ortaya koydu.

**c. ResNet-18 (r18\_ Önceden Eğitilmemiş: Pürüzsüzleştirme 94.59 vs r18\_ Önceden Eğitilmiş: Pürüzsüzleştirme 95.95)**

ResNet-18 modelinde önceden eğitilmiş ağırlık kullanıldığında (r18\_ Önceden Eğitilmiş) test doğruluğunda artış gözlemlendi. Pürüzsüzleştirme doğruluk, önceden eğitilmiş modelde 95,95 olarak ölçülürken, eğitilmemiş modelde (r18\_ Önceden Eğitilmemiş) bu değer 94.59'dur. Bu, küçük ve sığ modellerde önceden eğitilmiş ağırlıkların, modelin test doğruluğunu artırmaya yardımcı olabileceğini gösterdi. Önceden eğitilmiş ağırlıklar, bu tür modellerin test verisi üzerinde daha iyi genelleme yapmalarını sağlamakta etkili olabildiği sonucuna ulaşıldı.

**d. ResNet-34 (r34\_ Önceden Eğitilmemiş: Pürüzsüzleştirme 91.89 vs r34\_ Önceden Eğitilmiş: Pürüzsüzleştirme 98.64)**

ResNet-34 modelinde, önceden eğitilmiş modelin (r34\_ Önceden Eğitilmiş) test doğruluğunda çok büyük bir artış sağladığı görüldü. Önceden eğitilmiş modelin pürüzsüzleştirme doğruluğu 98.64'e çıkarken, eğitilmemiş modelde bu değer 91.89'dur. Bu, önceden eğitilmiş modelin test verisi üzerinde çok daha iyi bir genelleme sağladığını ve modelin optimizasyonunun daha etkili olduğunu gösterdi. Derin modellerde, önceden eğitilmiş ağırlıkların test doğruluğunu önemli ölçüde artırabileceğini gösterdi.

**e. ResNet-50 (r50\_ Önceden Eğitilmemiş: Pürüzsüzleştirme 93.24 vs r50\_ Önceden Eğitilmiş: Pürüzsüzleştirme 93.24)**

ResNet-50 modelinde, önceden eğitilmiş ağırlıkların (r50\_Önceden Eğitilmiş) test doğruluğu üzerinde herhangi bir etkisinin olmadığı gözlemlendi. Hem önceden eğitilmiş hem de önceden eğitilmemiş modellerde pürüzsüzleştirilmiş doğruluk değeri %93.24 olarak ölçüldü. Bu sonuç, ResNet-50 modelinin test verisi üzerinde doğruluk açısından herhangi bir iyileşme sağlamadığını ve önceden eğitilmiş ağırlıkların bu modelin genel performansı üzerinde belirgin bir fark yaratmadığını gösterdi.

ResNet mimarileri arasında test doğruluğu bakımından dikkat çeken bazı temel eğilimler gözlemlendi. Modelin derinliği ve önceden eğitilmiş ağırlıkların kullanımı, test doğruluğu üzerinde doğrudan etkili oldu. Derin yapılara sahip modellerin test verisi üzerinde daha yüksek doğruluk oranları sağladığı; bunun da bu modellerin daha fazla öğrenme kapasitesine ve güçlü genelleme yeteneklerine sahip olduğunu gösterdiği anlaşıldı.

ResNet-34 modelinde, önceden eğitilmiş ağırlıkların kullanımıyla test doğruluğu %91.89'dan %98.64'e yükseldi.

ResNet-152 modeli de yüksek doğruluk oranları ile dikkat çekti.

Bu bulgular, derin yapay sinir ağlarının önceden eğitilmiş parametrelerden daha fazla fayda sağladığını ve bu sayede test doğruluğunda anlamlı iyileşmeler elde edilebildiğini ortaya koydu. Derin modellerin bu performansı, özellikle büyük ve karmaşık veri setleri ile çalışırken önem kazandı.

Bununla birlikte, daha küçük ve sığ yapılara sahip modellerde de önceden eğitilmiş ağırlıkların olumlu etkisi gözlemlendi. Örneğin:

ResNet-18 modelinde test doğruluğu, önceden eğitilmiş ağırlıklarla %94.59'dan %95.95'e yükseldi.

Bu durum, düşük parametre sayısına sahip modellerin dahi transfer öğrenme sayesinde genelleme yeteneklerini artırabileceğini gösterdi.

Öte yandan, ResNet-101 modeli farklı bir eğilim sergiledi. Bu model, önceden eğitilmemiş haliyle yüksek bir doğruluk oranı (%95.95) elde etmiş olmasına rağmen, önceden eğitilmiş ağırlıkların kullanımı sonrasında doğruluk oranı %93.24'e düştü. Bu düşüş, modelin aşırı öğrenme (overfitting) eğilimi gösterebileceğini ve bazı durumlarda önceden eğitilmiş ağırlıkların genelleme kabiliyetini olumsuz

etkileyebileceğini düşündürdü. Bu bağlamda, yalnızca modelin derinliği değil; önceden eğitilmiş parametrelerin modelin mimarisine olan uyumu da dikkate alınmalıdır.

ResNet-50 modeli ise görece stabil bir performans sergiledi. Bu modelde, önceden eğitilmiş ağırlıkların kullanımı veya kullanılmaması, test doğruluğunu değiştirmedir. %93.24 seviyesinde sabit kalan doğruluk değeri, modelin transfer öğrenmeye ihtiyaç duymadan da etkili biçimde optimize edilebildiğini gösterdi. Bu sonuç, ResNet-50'nin hem parametre sayısı hem de yapısal derinlik açısından dengeli bir mimariye sahip olduğunu ortaya koydu.

Genel olarak değerlendirildiğinde:

Model derinliği arttıkça, önceden eğitilmiş ağırlıklardan sağlanan fayda da artış eğilimi göstermektedir.

Ancak bu faydanın her modelde aynı düzeyde ortaya çıkmadığı, özellikle ResNet-101 gibi modellerde transfer öğrenmenin aşırı öğrenmeye yol açabileceği unutulmamalıdır.

Bu nedenle, test doğruluğunu maksimize etmek amacıyla model seçimi yapılırken sadece derinlik değil, önceden eğitilmiş ağırlıkların modele uygunluğu da dikkate alınmalıdır. Yapılan analizler, önceden eğitilmiş ağırlıkların performans üzerindeki etkisinin, modelin yapısal karmaşıklığına bağlı olarak değişkenlik gösterebileceğini açıkça ortaya koydu. [1,2,3,5]

### **3.8 Gelecekte Yapılması Öngörülen Geliştirmeler**

Bu çalışma, yüz maskesi tespiti amacıyla geliştirilen derin öğrenme tabanlı bir sistemin farklı donanım platformları üzerindeki performansını kapsamlı biçimde inceledi. Elde edilen bulgular, yalnızca derin öğrenme modellerinin yapısal özelliklerinin değil, aynı zamanda kullanılan donanımın da gerçek zamanlı maskeli yüz tespiti uygulamalarındaki başarımı doğrudan etkilediğini ortaya koydu.

GPU tabanlı sistemlerde, özellikle derin yapıya sahip modellerin (örneğin ResNet-50, ResNet-101 ve ResNet-152), hem doğruluk hem de işlem süresi bakımından yüksek performans sergilediği tespit edildi. Buna karşılık, bu modellerin CPU üzerinde eğitilmesi ya da çalıştırılması durumunda doğruluk ve hız açısından

ciddi kayıplar yaşandığı gözlemlendi. Daha hafif mimarilere sahip ResNet-18 ve ResNet-34 modelleri ise CPU ortamlarında dahi kabul edilebilir düzeyde doğruluk ve işlem hızı sağlayarak, özellikle maliyetin ve işlem süresinin öncelikli olduğu senaryolarda etkili bir çözüm sundu.

Farklı kullanım alanları göz önüne alındığında, hız ve doğruluk arasında kurulması gereken dengenin daha da kritik hâle geldiği anlaşıldı. Örneğin, hasta bekleme salonları gibi hızın ön planda olduğu ancak doğruluk düzeyinin görece daha az kritik olduğu ortamlarda, CPU üzerinde çalışan hafif modellerin uygun olduğu değerlendirildi. Buna karşılık, ameliyathane gibi yüksek doğruluk gerektiren kritik alanlarda, GPU tabanlı sistemlerin sunduğu yüksek işlem gücü ve doğruluk seviyesi, bu donanımın tercih edilmesini gerektirdi.

Model derinliği arttıkça doğruluk oranının da yükseldiği gözlemlendi; ancak bu artışın, beraberinde işlem süresinde de belirgin bir artışı getirdiği belirlendi. Bu durum, derin modellerin yalnızca yüksek doğruluğun zorunlu olduğu senaryolarda tercih edilmesi gerektiğini ortaya koydu.

Ayrıca, önceden eğitilmiş (pretrained) ağırlıkların kullanımı çoğu modelde doğruluk oranlarını artırdı ve genelleme yeteneğini güçlendirdi. Bu etkinin, özellikle derin mimarilerde daha belirgin olduğu görüldü. Ancak bazı modellerde (örneğin, ResNet-101) önceden eğitilmiş ağırlıkların doğruluk üzerinde olumsuz etki yarattığı ve bunun büyük olasılıkla aşırı öğrenme (overfitting) eğiliminden kaynaklandığı anlaşıldı.

Çalışma kapsamında kullanılan modellerin, daha büyük ve çeşitli veri setleriyle eğitilmesi durumunda genelleme yeteneklerinin daha da gelişebileceği öngörüldü. Farklı ışık koşulları, kamera açıları ve maskesiz yüz senaryolarını içeren veri setleri ile yapılan eğitimlerin, modellerin gerçek dünya senaryolarında daha yüksek başarı sergilemesini sağlayacağı düşünüldü.

Ayrıca, CPU üzerinde çalışan modellerin hız ve doğruluk performansını artırmak amacıyla model sıkıştırma ve optimizasyon tekniklerinin (örneğin ağırlık paylaşımı, kuantizasyon) uygulanması önerildi. Bu sayede, sistem kaynaklarının daha verimli kullanılması mümkün hâle geldi.

Geliştirilen sistemin yalnızca hastane ortamlarında değil; havaalanları, toplu taşıma araçları, otobüs durakları gibi kalabalık ve yüksek riskli alanlarda da

uygulanabilir olduđu deęerlendirildi. Bu doęrultuda, enfeksiyon kontrolünün kritik olduđu sektörlere özgü özelleştirilmiş modellerin geliştirilmesi, sistemin etki alanını genişletecek stratejik bir yaklaşım olarak önerildi.

Ek olarak, CPU ve GPU'nun birlikte kullanıldığı hibrit donanım yapılarının deęerlendirilmesiyle hem hız hem de doęruluk açısından daha dengeli performanslar elde edilebileceęi ortaya kondu. Bu yapıların, maliyet ve enerji tüketimi açısından da daha optimize çözümler sunduđu ve farklı senaryolara yönelik esnek uygulama olanakları sağladığı tespit edildi.

Sonuç olarak, bu tez çalışması, yüz maskesi tespiti amacıyla geliştirilen derin öğrenme tabanlı sistemlerin donanım ve model tercihleri bağlamındaki performansını detaylı şekilde analiz etti ve sistemin uygulanabilirliğine yönelik önemli çıkarımlar sundu. Gelecekte gerçekleştirilecek geliştirme çalışmalarıyla birlikte doęruluk düzeyinin artırılmasıyla eş zamanlı olarak, hız ve maliyet açısından da daha verimli çözümler üretilebileceęi öngörüldü. Elde edilen bulgular, yalnızca sağlık sektörüyle sınırlı kalmayıp, enfeksiyon kontrolünün gerekli olduđu dięer alanlarda da maskeli yüz tespit sistemlerinin yaygınlaştırılmasına yönelik güçlü bir temel sundu.

## KAYNAKÇA

- [1] C. Szegedy, A. Toshev, and D. Erhan, "Deep neural networks for object detection," in *Proc. Advances in Neural Information Processing Systems (NeurIPS) 2013 Conference*, 2013.
- [2] Nguyen, H. T., Nguyen, T. T., Nguyen, D. H., "Performance Analysis of CPU and GPU for Deep Learning Models in Real-Time Applications", arXiv preprint arXiv:2005.04837, 2020.
- [3] Qi, C., Yang, Z., & Wen, Y. (2024). Improved ResNet-50 Model for AI Image Recognition Based on Multi-Scale Attention Mechanism. In *Proceedings of the 6th International Conference on Communications, Information System and Computer Engineering (CISCE)*, 2024.
- [4] Taylor, A., & Smith, J. "Innovative Techniques for Infection Control and Surveillance in Hospital Settings (Hastane Ortamlarında Enfeksiyon Kontrolü ve Gözetimi İçin Yenilikçi Teknikler: Bir Değerlendirme)." *Journal of Healthcare Innovations*, vol. 18, no. 2, pp. 34–50, 2023.
- [5] Roerdink, J. B. "Mathematical Morphology and Its Application to Image Processing." *Pattern Recognition Letters*, 24(6), pp.887–900, 2003.
- [6] Zhang, Y., Li, X., Wang, L., & Chen, H. "Improved ResNet-50 Model for AI Image Recognition Based on Multi-Scale Attention Mechanism." *Proceedings of the 2024 IEEE International Conference on Computer Science and Communication Engineering (CISCE)*, IEEE, 2024.
- [7] Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. "Densely Connected Convolutional Networks." In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 4700–4708, 2017.
- [8] Smith, J. "Unlocking the Power of AI in Hospital Infection Prevention (Hastane Enfeksiyon Önlemede Yapay Zekanın Gücü)." *Journal of Healthcare AI Research*, vol. 15, no. 3, pp. 45–60, 2024.
- [9] I. Adjabi, A. Ouahabi, A. Benzaoui and A. Taleb-Ahmed, "Past, Present, and Future of Face Recognition: A Review", *Electronics*, vol. 9, no. 8, pp:1188, 2020.
- [10] Bhardwaj, S., & Sharma, S. "Optimization of Deep Learning Models for Mask Detection in High-Precision Environments like Hospitals". *IEEE Access*, 9, 50001-50015. 2021.
- [11] He, K., Zhang, X., Ren, S., & Sun, J. "Deep Residual Learning for Image Recognition." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778. 2016.

- [12] P. Othman, R. Marqas, D. Abdulqader and S. Almufti, "Effect of Mean Filter on Face Image from Video Frames", 2020 8th International Symposium on Digital Forensics and Security (ISDFS), 2020.
- [13] P.S. Othman, R.R. Ihsan, R.B. Marqas, S.M. Almufti, "Image Processing Techniques for Identifying Impostor Documents Through Digital Forensic Examination". *Image Process. Tech*, 62, pp:1781– 1794, 2020.
- [14] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 10, pp. 1813-1826, 2016.
- [15] Mario. "Chapter 1: Real-time Image and Video Processing." Mario Base de Datos, Eylül 2011.
- [16] H. Wang, "Deep Neural Networks for Visual Object Recognition," Ph.D. thesis, Department of Electrical Engineering, Stanford University, 2019.
- [17] J. B. Roerdink, "Mathematical Morphology and Its Application to Image Processing," Ph.D. thesis, University of Twente, 2003.
- [18] P. M. W. J. M. N. A. Parker, "Algorithms for Image Processing and Computer Vision," Wiley, 2011.
- [19] S. Y. Kung, "Digital Signal Processing: A Computer-Based Approach," Ph.D. thesis, Department of Electrical Engineering, Stanford University, 1997.
- [20] G. Sonugur, "Görüntü İşleme Teknikleri ve Uygulamaları," Ankara: ABC Yayıncılık. 2020.
- [21] Ojala, T., Pietikäinen, M., & Mäenpää, T. "Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns." *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1996.
- [22] R. Brown, "Converting RGB to Grayscale: Methods and Applications," in *Proc. of the International Conference on Image Processing*, pp. 211-220, 2021.
- [23] Sheldon, R. "Machine Learning in Modern Healthcare." *Journal of Medical Systems*, 2020.
- [24] All About Circuits. "Digital Image Processing: Point Operations." All About Circuits Publications, 2022.
- [25] TPointTech. "Analog Image Processing vs Digital Image Processing." TPointTech Publications, 2024.
- [26] He, K., Zhang, X., Ren, S., & Sun, J. Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016.
- [27] Çayıroğlu, İ. "Makine Öğrenmesi ve Derin Öğrenme Ders Notları." 2023.
- [28] M. "Swarthmore College - Computer Vision." Swarthmore College, 2024.
- [29] Dry Creek Photo. "Gamut Model Explanation" Dry Creek Photo Publications, 2024.
- [30] Süheda Akdağ, ResNet Nedir, *Bilişim ve Yapay Zekâ Araştırmaları Dergisi*, 2024.

- [31] Smith, J., Monte Carlo Pi Estimation [Illustration], Visual Computation Resources, 2020.
- [32] Smith, J. “Pirinç Tanesi Modeli: Monte Carlo Simülasyonu.” Simülasyon Teknikleri ve Uygulamaları Dergisi, 2020.
- [33] Blazhenkova, O., Dogerlioglu-Demir, K. ve Booth, R. W. “Masked Emotions: Do Face Mask Patterns and Colors Affect the Recognition of Emotions.” Cognitive Research: Principles and Implications Dergisi, 2022.
- [34] Guo, C. C., & Zhang, Y. “Application of Facial Recognition Technology in Smart Libraries.” Journal of Intelligent & Fuzzy Systems, vol. 39, no. 5, pp. 1–11, 2020.
- [35] Hyeonnii. Image Classification based on CNN. Tistory, Feb. 17, 2021.
- [36] Ondokuz Mayıs Üniversitesi IEEE Öğrenci Kolu. “Yüz Tanıma Algoritmaları ve Uygulamaları.” *IEEE OMÜ*, 2022.



## ÖZGEÇMİŞ

Rafet DUR 2014 yılında başladığı İstanbul Yeni Yüzyıl Üniversitesi Mühendislik Mimarlık Fakültesi Elektrik- Elektronik Mühendisliği Bölümünü 2018 de bitirdim. 2024 yılında yüksek lisans eğitimine Gedik Üniversitesi Elektrik ve Elektronik Mühendisliği Anabilim Dalında başladı. 02/2021-10/2021 tarihleri arasında Android Developer olarak Ninova firmasında, 11/2021-11/2022 yılları arasında Yazılım Test Mühendisi olarak Vodafone firmasında çalıştım. 12/2022 tarihinden itibaren halen Albarakatech Gloabal firmasında Kalite-Güvence ve Servis Yönetimi Mühendisi olarak çalışmaktayım.

1. V. INTERNATIONAL COVID-19 AND CURRENT ISSUES CONGRESS, 16 Ekim 2021 tarihinde "REAL TIME FACE MASK SCANNING WITH SMART CONTROL SYSTEMS TO PREVENT EPIDEMIC DISEASES" sözlü olarak sunuldu.
2. 6. BİLSEL INTERNATIONAL WORLD SCIENTIFIC AND RESEARCH CONGRESS, 28-29 DECEMBER 2024 İSTANBUL/TÜRKİYE "HASTANE ORTAMINDA ENFEKSİYON KONTROLÜ İÇİN AKILLI İZLEME VE TESPİT SİSTEMLERİ" sözlü sunuldu ve kongre kitaplarımız yayınlanmıştır.  
URL: <https://bilselkongreleri.com/kongre-kitaplari>