



**PİKSEL BAZLI YENİ YÖNTEMLERLE DÜŞÜK  
AYDINLIKLİ GÖRÜNTÜLERİN  
İYİLEŞTİRİLMESİ**

**Yasin DEMİR**

**Doktora Tezi**

**Elektrik Elektronik Mühendisliği Ana Bilim Dalı**

**2025**

(Her hakkı saklıdır.)

**T.C.**  
**ERZURUM TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**



**PİKSEL BAZLI YENİ YÖNTEMLERLE DÜŞÜK AYDINLIKLIL  
GÖRÜNTÜLERİN İYİLEŞTİRİLMESİ**

**DOKTORA TEZİ**  
**Yasin DEMİR**

**Danışman:** Prof. Dr. Nur Hüseyin KAPLAN

**ERZURUM, 2025**

**T.C.**  
**ERZURUM TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**TEZ KABUL VE ONAY TUTANAĞI**

---

**PİKSEL BAZLI YENİ YÖNTEMLERLE DÜŞÜK AYDINLIKLİ  
GÖRÜNTÜLERİN İYİLEŞTİRİLMESİ**

Prof. Dr. Nur Hüseyin KAPLAN danışmanlığında, Yasin DEMİR tarafından hazırlanan bu çalışma 10.11.2025 tarihinde aşağıdaki jüri tarafından Ana Bilim Dalı Seçiniz Ana Bilim Dalı'nda Doktora tezi olarak **Oy birliği ile (5/5)** kabul edilmiştir.

|                  |                                                                    |                   |
|------------------|--------------------------------------------------------------------|-------------------|
| <b>Danışman:</b> | Prof. Dr. Nur Hüseyin KAPLAN<br><i>Erzurum Teknik Üniversitesi</i> | <i>İmza</i> ..... |
| <b>Üye:</b>      | Prof. Dr. İbrahim Yücel ÖZBEK<br><i>Atatürk Üniversitesi</i>       | <i>İmza</i> ..... |
| <b>Üye:</b>      | Doç. Dr. Mehmet BAYĞIN<br><i>Erzurum Teknik Üniversitesi</i>       | <i>İmza</i> ..... |
| <b>Üye:</b>      | Doç. Dr. Emin Argun ORAL<br><i>Atatürk Üniversitesi</i>            | <i>İmza</i> ..... |
| <b>Üye:</b>      | Dr. Öğr. Üyesi Sefa KÜÇÜK<br><i>Erzurum Teknik Üniversitesi</i>    | <i>İmza</i> ..... |

Yukarıdaki sonucu onaylıyorum.

**Prof. Dr. İlker KAZAZ**  
**Enstitü Müdürü**

## **ÜRETKEN YAPAY ZEKÂ VE ETİK KURALLARA UYGUNLUK BEYANI**

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etik ilkelere uygun davrandığımı ve tezin hazırlanması sürecinde üretken yapay zekâ programlarından, içeriğin ve sonuçların özgünlük sorumluluğunun tarafıma ait olması ve çalışmanın bilimsel niteliğini etkilemeyecek düzeyde, yalnızca yardımcı bir araç olarak sınırlı düzeyde destek alındığını beyan ederim.

10.11.2025

Yasin DEMİR

## **TEŞEKKÜR**

Doktora eğitimim süresince değerli bilgi ve tecrübeleriyle bana yol gösteren, akademik gelişimime önemli katkılar sağlayan, tez çalışmamın planlanması, yürütülmesi ve sonuçlandırılması aşamalarında her zaman desteğini esirgemeyen, sabrı ve hoşgörüsüyle bana daima güven veren kıymetli danışmanım Sayın Prof. Dr. Nur Hüseyin KAPLAN'a en içten teşekkürlerimi sunarım.

Tez İzleme Komitesinde yer alarak çalışmamı yakından takip eden, yapıcı eleştirileri ve yol gösterici önerileriyle tezimin gelişimine önemli katkılar sunan Sayın Doç. Dr. Mehmet BAYĞIN'a ve Sayın Dr. Öğr. Üyesi Sefa KÜÇÜK'e teşekkür ederim.

Hayatım boyunca her zaman yanımda olan, sevgileri, sabırları ve fedakarlıklarıyla beni bugünlere getiren kıymetli aileme en derin teşekkürlerimi sunarım.

Doktora sürecim boyunca her zaman yanımda olan, anlayışı, sabrı ve desteğiyle bana güç veren, sevgisiyle en büyük motivasyon kaynağım olan sevgili eşim Büşra AYDIN DEMİR'e sonsuz teşekkürlerimi sunarım.

**Yasin DEMİR**

## ÖZET

DOKTORA TEZİ

### PIKSEL BAZLI YENİ YÖNTEMLERLE DÜŞÜK AYDINLIKLIL GÖRÜNTÜLERİN İYİLEŞTİRİLMESİ

Yasin DEMİR

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

**Danışman:** Prof. Dr. Nur Hüseyin KAPLAN

Düşük aydınlıklı görüntü iyileştirme, görüntü işleme alanında önemli araştırma konularından biridir. Yetersiz aydınlatma koşullarında yakalanan görüntüler; düşük karışıklık, renk bozulmaları ve yüksek gürültü gibi sorunlar sebebiyle hem insan algısında hem de bilgisayarlı görü uygulamalarında bozucu etkiler meydana getirmektedir. Bu bağlamda, düşük aydınlıklı görüntülerin iyileştirilmesi ileri görüntü işleme adımları açısından kritik öneme sahiptir. Buradan hareketle, herhangi bir renk bozulması ve gürültü artışı olmadan düşük aydınlıklı görüntülerin karışıklık, aydınlatma ve detay bilgilerinin iyileştirilmesi hedeflenmektedir. Bu tez çalışması kapsamında “Keskinleştirme-Yumuşatma Görüntü Filtresine Dayalı Yaklaşım”, “Metropolis Teoremine Dayalı Yaklaşım”, “Yeni Renk Kanalı Odaklı Fiziksel Aydınlatma Modeline Dayalı Yaklaşım”, “Uyarlanabilir Krominans Gama Düzeltmesine Dayalı Yaklaşım” olmak üzere dört farklı düşük aydınlıklı görüntü iyileştirme yöntemi önerilmiştir.

Önerilen yöntemler, teorik altyapıları ve kullanmış oldukları stratejiler açısından detaylı bir şekilde açıklanmıştır. Literatürde sıklıkla kullanılan veri kümeleri üzerinde hem görsel hem nicel karşılaştırmalı analizleri yapılarak güçlü yönleri ve sınırlılıkları net bir biçimde ortaya konmuştur. Elde edilen bulgular, her senaryo için en iyi çözümün olmadığını, önerilen her yöntemin farklı düşük aydınlık senaryosunda ön plana çıktığını göstermektedir. Değerlendirme sonuçları, düşük aydınlıklı görüntü iyileştirme probleminin sahne bağımlı bir yapısı olduğunu da göstermektedir. Bu sebeple, farklı uygulamalar için farklı yaklaşımların benimsenmesi gerektiği açıktır. Bu tez çalışması, düşük aydınlıklı görüntü iyileştirme alanında önerilen yöntemleri kapsamlı bir şekilde analiz ederek güçlü yönlerini ve sınırlılıklarını ortaya koymaktadır. Aynı zamanda, düşük aydınlıklı görüntü iyileştirme alanında ileride yapılması hedeflenen çalışmalara ışık tutmaktadır.

**Anahtar Kelimeler:** Düşük Aydınlıklı Görüntü İyileştirme, Keskinleştirme-Yumuşatma Görüntü Filtresi, Metropolis Teoremi, Yeni Renk Kanalı, Fiziksel Aydınlatma Modeli, İki Yanlı Filtre, En Küçük Kareler

## **ABSTRACT**

PhD THESIS

### **NEW PIXEL-BASED METHODS for LOW LIGHT IMAGE ENHANCEMENT**

Yasin DEMİR

Erzurum Technical University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

**Supervisor:** Prof. Dr. Nur Hüseyin KAPLAN

Low-light image enhancement is one of the most important research topics in the field of image processing. Images captured in low-light environments exhibit artifacts that affect both human perception and computer vision applications due to issues such as low contrast, color distortion, and severe noise. Therefore, low-light image enhancement plays a critical role in advanced image processing tasks. The aim of low-light image enhancement is to improve contrast, illumination, and detail information in low-light images without introducing color distortion or noise amplification. In this thesis, four different low-light image enhancement methods are proposed: “Sharpening-Smoothing Image Filter based method”, “Metropolis Theorem based method”, “New Color Channel Driven Physical Lighting Model based method”, and “Adaptive Chrominance Gamma Correction based method”.

The proposed methods are explained in detail with regard to their theoretical background and the strategies they employ. Comparative analyses, both visual and quantitative, are conducted on frequently used datasets in the literature to clearly demonstrate their strengths and limitations. The findings reveal that there is no universal optimal solution, and that each proposed method becomes more effective in different low-light scenarios. The evaluation results indicate that the low-light image enhancement problem is highly scene-dependent. Therefore, it is evident that different approaches should be adopted for different applications. This thesis comprehensively analyzes the proposed methods for low-light image enhancement, highlighting their strengths and limitations, and also provides insights into potential future work in this field.

**Keywords:** Low-light Image Enhancement, Sharpening-Smoothing Image Filter, Metropolis Theorem, New Color Channel, Physical Lighting Model, Bilateral Filter, Least Squares

## İÇİNDEKİLER

|                                                                                                                              |      |
|------------------------------------------------------------------------------------------------------------------------------|------|
| ÜRETKEN YAPAY ZEKÂ VE ETİK KURALLARA UYGUNLUK BEYANI .....                                                                   | i    |
| TEŞEKKÜR .....                                                                                                               | ii   |
| ÖZET.....                                                                                                                    | iii  |
| ABSTRACT .....                                                                                                               | iv   |
| İÇİNDEKİLER .....                                                                                                            | v    |
| TABLolar DİZİNİ .....                                                                                                        | viii |
| ŞEKİLLER DİZİNİ .....                                                                                                        | ix   |
| KISALTMALAR VE SİMGELER DİZİNİ .....                                                                                         | xii  |
| 1. GİRİŞ .....                                                                                                               | 1    |
| 1.1. Tezin Amacı .....                                                                                                       | 3    |
| 1.2. Literatürde Kullanılan Düşük Aydınlıklı Görüntü İyileştirme Yöntemleri.....                                             | 3    |
| 1.2.1. Gri Seviye Dönüşümü Tabanlı Yöntemler .....                                                                           | 4    |
| 1.2.2. Histogram Eşitleme Tabanlı Yöntemler .....                                                                            | 6    |
| 1.2.3. Retineks Tabanlı Yöntemler .....                                                                                      | 9    |
| 1.2.4. Derin Öğrenme Tabanlı Yöntemler .....                                                                                 | 14   |
| 1.2.5. Diğer Geleneksel Yöntemler .....                                                                                      | 30   |
| 1.3. Tezin Literatüre Katkıları .....                                                                                        | 32   |
| 1.4. Tezin Akışı .....                                                                                                       | 34   |
| 2. MATERYAL VE YÖNTEM.....                                                                                                   | 35   |
| 2.1. Önerilen Keskinleştirme-Yumuşatma Görüntü Filtresine Dayalı Düşük<br>Aydınlıklı Görüntü İyileştirme (SSIF).....         | 35   |
| 2.1.1. SSIF ile Çok Ölçekli Ayırıştırma .....                                                                                | 35   |
| 2.1.2. Düşük Aydınlık İyileştirme Şeması.....                                                                                | 36   |
| 2.2. Önerilen Metropolis Teoremine Dayalı Piksel Bazında Düşük Aydınlıklı<br>Görüntü İyileştirme (MT) .....                  | 38   |
| 2.2.1. Metropolis teoremi ile çok ölçekli ayırıştırma.....                                                                   | 38   |
| 2.2.2. Düşük Aydınlık İyileştirme Şeması.....                                                                                | 39   |
| 2.3. Önerilen Düşük Aydınlıklı Görüntü İyileştirme İçin Yeni Renk Kanalı Odaklı<br>Fiziksel Aydınlatma Modeli (NCC-PLM)..... | 42   |
| 2.3.1. Yeni Renk Kanalı Önseli .....                                                                                         | 42   |

|                                                                                 |            |
|---------------------------------------------------------------------------------|------------|
| 2.3.2. Gama Düzeltme Stratejisi .....                                           | 43         |
| 2.3.3. Işık Saçılım Zayıflama Oranı Tahmini ve Yeniden Yapılandırma.....        | 44         |
| 2.4. Önerilen Düşük Aydınlıklı Görüntü İyileştirme İçin Uyarlanabilir Krominans |            |
| Gama Düzeltme (ACGC) .....                                                      | 45         |
| 2.4.1. İki Yanlı Filtre-En Küçük Kareler ile Ayırıştırma.....                   | 46         |
| 2.4.2. Düşük Aydınlık İyileştirme Şeması.....                                   | 46         |
| <b>3. ARAŞTIRMA BULGULARI VE TARTIŞMA.....</b>                                  | <b>49</b>  |
| 3.1. Karşılaştırmada Kullanılan Yöntemler.....                                  | 49         |
| 3.2. Kullanılan Veri Kümeleri.....                                              | 49         |
| 3.3. Performans Ölçütleri .....                                                 | 50         |
| 3.4. Önerilen SSIF Yöntemi Sonuçları.....                                       | 53         |
| 3.4.1. Uygulama Detayları.....                                                  | 53         |
| 3.4.2. Görsel Sonuçlar .....                                                    | 53         |
| 3.4.3. Nicel Sonuçlar .....                                                     | 59         |
| 3.4.4. Bulgular .....                                                           | 62         |
| 3.5. Önerilen MT Yöntemi Sonuçları.....                                         | 63         |
| 3.5.1. Uygulama Detayları.....                                                  | 63         |
| 3.5.2. Görsel Sonuçlar .....                                                    | 65         |
| 3.5.3. Nicel Sonuçlar .....                                                     | 69         |
| 3.5.4. Bulgular .....                                                           | 72         |
| 3.6. Önerilen NCC-PLM Yöntemi Sonuçları .....                                   | 72         |
| 3.6.1. Uygulama Detayları.....                                                  | 72         |
| 3.6.2. Görsel Sonuçlar .....                                                    | 73         |
| 3.6.3. Nicel Sonuçlar .....                                                     | 82         |
| 3.6.4. Bulgular .....                                                           | 84         |
| 3.7. Önerilen ACGC Yöntemi Sonuçları.....                                       | 85         |
| 3.7.1. Uygulama Detayları.....                                                  | 85         |
| 3.7.2. Görsel Sonuçlar .....                                                    | 87         |
| 3.7.3. Nicel Sonuçlar .....                                                     | 92         |
| 3.7.4. Bulgular .....                                                           | 94         |
| 3.8. Önerilen Yöntemlerin Değerlendirilmesi .....                               | 95         |
| <b>4. SONUÇ VE ÖNERİLER.....</b>                                                | <b>97</b>  |
| <b>KAYNAKÇA .....</b>                                                           | <b>100</b> |
| <b>TEZDEN ÜRETİLEN YAYINLAR.....</b>                                            | <b>110</b> |

|                           |     |
|---------------------------|-----|
| 1. Makaleler.....         | 110 |
| 2. Bildiriler .....       | 110 |
| 3. Diğer Makaleler.....   | 110 |
| 4. Diğer Bildiriler ..... | 110 |



## TABLÖLAR DİZİNİ

|                                                                                                                                               |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Tablo 2.1.</b> Önerilen SSIF yöntemi ile iyileştirme için sözde kod. ....                                                                  | 37 |
| <b>Tablo 2.2.</b> Önerilen MT yöntemi ile iyileştirme için sözde kod. ....                                                                    | 41 |
| <b>Tablo 2.3.</b> Ortalama yoğunluk değerlerine göre düşük aydınlıklı görüntülerinin kategorilere ayrılması. ....                             | 44 |
| <b>Tablo 2.4.</b> Önerilen ACGC yöntemi ile iyileştirme için sözde kod. ....                                                                  | 48 |
| <b>Tablo 3.1.</b> Karşılaştırma veri kümeleri için referanslı metrik sonuçları.....                                                           | 60 |
| <b>Tablo 3.2.</b> Karşılaştırma veri kümeleri için referanssız metrik sonuçları. ....                                                         | 60 |
| <b>Tablo 3.3.</b> Karşılaştırmada kullanılan yöntemlerin ortalama çalışma zamanı (sn) ve eğitilebilir parametrelerinin karşılaştırılması..... | 62 |
| <b>Tablo 3.4.</b> Her bir bileşenin sırayla çıkarılmasıyla elde edilen nicel sonuçlar.....                                                    | 64 |
| <b>Tablo 3.5.</b> İki farklı veri kümesine ait referanslı metrik sonuçları.....                                                               | 70 |
| <b>Tablo 3.6.</b> Yedi farklı veri kümesine ait NIQE sonuçları.....                                                                           | 70 |
| <b>Tablo 3.7.</b> Karşılaştırmada kullanılan yöntemlerin ortalama çalışma zamanı (sn) ve eğitilebilir parametrelerinin kıyaslanması. ....     | 71 |
| <b>Tablo 3.8.</b> Üç farklı veri kümesine ait referanslı metrik sonuçları.....                                                                | 82 |
| <b>Tablo 3.9.</b> Yedi farklı veri kümesine ait referanssız metrik sonuçları. ....                                                            | 83 |
| <b>Tablo 3.10.</b> Ortalama çalışma zamanı (sn) ve eğitilebilir parametrelerin karşılaştırılması.....                                         | 84 |
| <b>Tablo 3.11.</b> İki farklı veri kümesine ait PSNR ve SSIM değerleri.....                                                                   | 92 |
| <b>Tablo 3.12.</b> Altı farklı veri kümesine ait NIQE değerleri. ....                                                                         | 93 |
| <b>Tablo 3.13.</b> Karşılaştırmada kullanılan yöntemlere ait ortalama çalışma zamanı (sn) ve eğitilebilir parametre değerleri. ....           | 94 |

## ŞEKİLLER DİZİNİ

|                                                                                                                                                                                                                                   |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 1.1.</b> (a) Düzensiz aydınlatmalı görüntü, (b) arkadan aydınlatmalı görüntü, (c) ekstra karanlık görüntü, (d) düşük pozlamalı görüntü, (e) gürültülü görüntü, (f) yerel düşük aydınlıklı görüntü. ....                  | 1  |
| <b>Şekil 1.2.</b> (a) Düşük pozlamalı görüntü, (b) yüksek pozlamalı görüntü, (c) kesin referans görüntüsü. ....                                                                                                                   | 4  |
| <b>Şekil 1.3.</b> Yinelemeli İki Yanlı Retineks yöntemi. ....                                                                                                                                                                     | 11 |
| <b>Şekil 1.4.</b> Uçtan uca öğrenme yöntemlerine ait temel yapı. ....                                                                                                                                                             | 14 |
| <b>Şekil 1.5.</b> Ayırıştırma tabanlı öğrenme yöntemlerine ait temel yapı. ....                                                                                                                                                   | 19 |
| <b>Şekil 1.6.</b> Füzyon tabanlı öğrenme yöntemlerine ait temel yapı. ....                                                                                                                                                        | 24 |
| <b>Şekil 1.7.</b> Denetimsiz öğrenme tabanlı yöntemlere ait temel yapı. ....                                                                                                                                                      | 28 |
| <b>Şekil 2.1.</b> Çok ölçekli SSIF için iki seviyeli ayırıştırma akış şeması. ....                                                                                                                                                | 36 |
| <b>Şekil 2.2.</b> Önerilen SSIF yöntemine ait akış şeması. ....                                                                                                                                                                   | 38 |
| <b>Şekil 2.3.</b> MT ile iki seviyeli ayırıştırma akış şeması. ....                                                                                                                                                               | 39 |
| <b>Şekil 2.4.</b> Önerilen MT yöntemine ait akış şeması. ....                                                                                                                                                                     | 40 |
| <b>Şekil 2.5.</b> Önerilen NCC-PLM yöntemine ait akış şeması. ....                                                                                                                                                                | 42 |
| <b>Şekil 2.6.</b> Farklı işlemler için ışık saçılım zayıflama oranı tahminleri. Yerel bölge boyutu $\Omega=31 \times 31$ ve karartma faktörü $\theta=0,2$ olarak ayarlanmıştır. ....                                              | 43 |
| <b>Şekil 2.7.</b> Farklı karartma faktörü değerleri için iyileştirme sonuçları. ....                                                                                                                                              | 44 |
| <b>Şekil 2.8.</b> Önerilen ACGC yöntemine ait akış şeması. ....                                                                                                                                                                   | 46 |
| <b>Şekil 3.1.</b> Farklı kappa değerleri ile elde edilen PSNR değerleri. ....                                                                                                                                                     | 53 |
| <b>Şekil 3.2.</b> Eyfel Kulesi-1 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                       | 54 |
| <b>Şekil 3.3.</b> Sokak-1 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                              | 55 |
| <b>Şekil 3.4.</b> Gündüz-1 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                             | 56 |
| <b>Şekil 3.5.</b> Kişi-1 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                               | 57 |
| <b>Şekil 3.6.</b> Yol-1 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                | 57 |
| <b>Şekil 3.7.</b> Otoyol görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                               | 58 |
| <b>Şekil 3.8.</b> Yaya geçidi görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                          | 59 |
| <b>Şekil 3.9.</b> Her bir bileşenin sırayla çıkarılmasıyla elde edilen görsellerin karşılaştırılması. (a) Giriş görüntüsü, (b) GC uygulanmadan elde edilen sonuç görüntüsü, (c) HSV uygulanmadan elde edilen sonuç görüntüsü, (d) |    |

|                                                                                                                                                                                                                                                                                                                                                                                                                          |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| MT uygulanmadan elde edilen sonuç görüntüsü, (e) LGC uygulanmadan elde edilen sonuç görüntüsü, (f) önerilen yöntem ile elde edilen sonuç görüntüsü.                                                                                                                                                                                                                                                                      | 63 |
| Şekil 3.10. Farklı MT ayrıştırma seviyelerinin etkisine ilişkin deneysel çalışmalar. ....                                                                                                                                                                                                                                                                                                                                | 64 |
| Şekil 3.11. Nehir görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                             | 65 |
| Şekil 3.12. Sokak-2 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                           | 66 |
| Şekil 3.13. Arkadan Aydınlatmalı-1 görüntü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                              | 67 |
| Şekil 3.14. Gün batımı görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                        | 67 |
| Şekil 3.15. Gündüz-2 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                          | 68 |
| Şekil 3.16. Kişi-2 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                            | 68 |
| Şekil 3.17. Aşırı karanlık görüntü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                      | 69 |
| Şekil 3.18. Önerilen yöntemin parametre belirleme deneyleri. (a) Farklı görüntü kategorileri için gama değerlerinin etkisi, (b) karartma faktörünün etkisi, (c) yama boyutunun etkisi. ....                                                                                                                                                                                                                              | 73 |
| Şekil 3.19. Tablo görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                             | 74 |
| Şekil 3.20. Müze görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                              | 74 |
| Şekil 3.21. Tiyatro görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                           | 75 |
| Şekil 3.22. Şehir-1 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                           | 76 |
| Şekil 3.23. Lunapark görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                          | 76 |
| Şekil 3.24. Anıt görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                              | 77 |
| Şekil 3.25. Kişi-3 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                            | 78 |
| Şekil 3.26. Kişi-4 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                            | 78 |
| Şekil 3.27. Kişi-5 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                            | 79 |
| Şekil 3.28. Sokak-3 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                           | 80 |
| Şekil 3.29. Arkadan Aydınlatmalı Görüntü-2 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                    | 80 |
| Şekil 3.30. Yol-2 görüntüsü için iyileştirme sonuçları. ....                                                                                                                                                                                                                                                                                                                                                             | 81 |
| Şekil 3.31. Farklı CLAHE parametreleri için ortalama PSNR değerleri. (a) Blok boyutu, (b) kırpma limiti. ....                                                                                                                                                                                                                                                                                                            | 85 |
| Şekil 3.32. Her bir bileşenin sırayla çıkarılmasıyla elde edilen görsellerin karşılaştırılması. (a) Giriş görüntüsü, (b) kesin referans görüntüsü, (c) GC uygulanmadan elde edilen sonuç görüntüsü, (d) LGC uygulanmadan elde edilen sonuç görüntüsü, (e) BLF-LS uygulanmadan elde edilen sonuç görüntüsü, (f) CLAHE uygulanmadan elde edilen sonuç görüntüsü, (g) önerilen yöntem ile elde edilen sonuç görüntüsü. .... | 86 |

|                                                                                              |    |
|----------------------------------------------------------------------------------------------|----|
| <b>Şekil 3.33.</b> Düzensiz Aydınlatmalı Görüntü için iyileştirme sonuçları. ....            | 87 |
| <b>Şekil 3.34.</b> İç Mekan görüntüsü için iyileştirme sonuçları. ....                       | 88 |
| <b>Şekil 3.35.</b> Şehir-2 görüntüsü için iyileştirme sonuçları. ....                        | 89 |
| <b>Şekil 3.36.</b> Ekstra Karanlık Görüntü için iyileştirme sonuçları. ....                  | 90 |
| <b>Şekil 3.37.</b> Eyfel Kulesi-2 görüntüsü için iyileştirme sonuçları. ....                 | 91 |
| <b>Şekil 3.38.</b> Arkadan Aydınlatmalı Görüntü-3 görüntüsü için iyileştirme sonuçları. .... | 92 |



## KISALTMALAR VE SİMGELER DİZİNİ

|          |                                                                                                                                               |
|----------|-----------------------------------------------------------------------------------------------------------------------------------------------|
| AHE      | Adaptive Histogram Equalization (Uyarlanabilir Histogram Eşitleme)                                                                            |
| AIEBHE   | Adaptive Image Enhancement based on Bi-Histogram Equalization (Bi-Histogram Eşitlemeye Dayalı Uyarlanabilir Görüntü İyileştirme)              |
| AMBE     | Absolute Mean Brightness Error (Mutlak Ortalama Parlaklık Hatası)                                                                             |
| BBHE     | Brightness Preserving Bi-Histogram Equalization (Parlaklık Koruyan Bi-Histogram Eşitleme)                                                     |
| BDD-100K | Berkeley DeepDrive One Hundred Thousand Veri Kümesi                                                                                           |
| BLF-LS   | Bilateral Filter in Least Squares (İki Yanlı Filtre-En Küçük Kareler)                                                                         |
| BSD      | Berkeley Segmentation Dataset (Berkeley Segmentasyon Veri Kümesi)                                                                             |
| CAN      | Context Aggregation Network (Çok Ölçekli Bağlam Toplama Ağı)                                                                                  |
| CDF      | Cumulative Density Function (Kümülatif Dağılım Fonksiyonu)                                                                                    |
| CIDNet   | Contextual Image Denoising Network (Bağlamsal Görüntü Gürültü Giderme Ağı)                                                                    |
| CLAHE    | Contrast Limited Adaptive Histogram Equalization (Karşıtlık Sınırlı Uyarlanabilir Histogram Eşitleme)                                         |
| CSDNet   | Context Sensitive Decomposition Network (Bağlam Duyarlı Ayırıştırma Ağı)                                                                      |
| CWAN     | Color-Wise Attention Network (Renk Bazlı Dikkat Ağını)                                                                                        |
| ÇA       | Çevresel Aydınlatma                                                                                                                           |
| DeepUPE  | Underexposed Photo Enhancement using Deep Illumination Estimation (Derin Aydınlatma Tahmini Kullanılarak Düşük Pozlanmış Fotoğraf Geliştirme) |
| DICM     | Digital Camera Images Veri Kümesi                                                                                                             |
| DRBN     | Deep Recursive Band Network (Derin Yinelemeli Bant Ağı)                                                                                       |
| DRGN     | Degradation-to-Refinement Generation Network (Bozunma Geliştirme Üretim Ağı)                                                                  |
| DSIHE    | Dual Sub-Image Histogram Equalization (İkili Alt Görüntü Histogram Eşitleme)                                                                  |
| EEMEFN   | Edge-Enhanced Multi-Exposure Fusion Network (Kenar İyileştirilmiş Çoklu Pozlamalı Füzyon Ağını)                                               |

|           |                                                                                                                                  |
|-----------|----------------------------------------------------------------------------------------------------------------------------------|
| ESA       | Evrişimsel Sinir Ağı (Convolutional Neural Network)                                                                              |
| ESDNet    | Efficient Scale-Aware Demoiréing Network (Verimli Ölçek Duyarlı Demoire Ağı)                                                     |
| ExDark    | Exclusively Dark Veri Kümesi                                                                                                     |
| FCN       | Fully-Convolutional Netwok (Tam Evrişimli Ağ)                                                                                    |
| FENet     | Füzyon İyileştirme Ağı                                                                                                           |
| FFT       | Fast Fourier Transform (Hızlı Fourier Dönüşümü)                                                                                  |
| GC        | Gamma Correction (Gama Düzeltmesi)                                                                                               |
| GCP-MCS   | Gamma Correction Prior in Mixed Color Spaces (Karışık Renk Uzaylarında Gama Düzeltme Önseli)                                     |
| GHE       | Global Histogram Equalization (Genel Histogram Eşitleme)                                                                         |
| GHz       | Gigahertz                                                                                                                        |
| GİB       | Grafik İşlem Birimi                                                                                                              |
| GLADNet   | Global Illumination Aware and Detail Preserving Network (Küresel Aydınlatma Duyarlı ve Detay Koruyan Ağı)                        |
| GLINet    | Global-Local Interaction Network (Genel-Yerel Etkileşim Ağı)                                                                     |
| HE        | Histogram Eşitleme                                                                                                               |
| ISZO      | Işık Saçılım Zayıflama Oranı                                                                                                     |
| KBR       | Kernel-Based Retinex (Çekirdek Tabanlı Retineks)                                                                                 |
| KinD      | Kindling the Darkness Veri Kümesi                                                                                                |
| LCDPNet   | Local Color Distributions Prior Network (Yerel Renk Dağılımları Önseli Ağı)                                                      |
| LENFusion | Low-Light Enhancement and Fusion (Düşük Aydınlik Görüntü İyileştirme ve Füzyonu)                                                 |
| LGC       | Local Gamma Correction (Yerel Gama Düzeltmesi)                                                                                   |
| LHE       | Local Histogram Equalization (Yerel Histogram Eşitleme)                                                                          |
| LIEQA     | Low-Light Image Enhancement Quality Assessment (Düşük Aydınlik Görüntü İyileştirme Kalitesi Değerlendirmesi)                     |
| LIME      | Low-Light Image Enhancement via Illumination Map Estimation (Aydınlatma Haritası Tahmini ile Düşük Aydınlik Görüntü İyileştirme) |
| LLEDNet   | Low-light Encoder-Decoder Network (Düşük Aydınlik Kodlayıcı Kod Çözücü Ağını)                                                    |
| LLNet     | Low-light Net (Düşük Aydınlik Ağı)                                                                                               |

|                 |                                                                                                                                                    |
|-----------------|----------------------------------------------------------------------------------------------------------------------------------------------------|
| LOL             | Low-Light Veri Kümesi                                                                                                                              |
| LR3M            | Robust Low-Light Enhancement via Low-Rank Regularized Retinex Model (Düşük Dereceli Düzenli Retineks Modeli ile Gürbüz Düşük Aydınlik İyileştirme) |
| MBLLEN          | Multi-Branch Low-light Enhancement Network (Çok Dalı Düşük Aydınliklı İyileştirme Ağını)                                                           |
| MEF             | Multi-Exposure Fusion Veri Kümesi                                                                                                                  |
| MEPCR           | Multi-Exposure Progressive Contrastive (RegularizationÇoklu Pozlamalı Kademeli Karşıtlıklı Düzenleme)                                              |
| MIT Adobe FiveK | Massachusetts Institute of Technology Adobe Five Thousand Veri Kümesi                                                                              |
| MİB             | Merkezi İşlem Birimi                                                                                                                               |
| MMBEBHE         | Minimum Mean Brightness Error Bi-Histogram Equalization (Minimum Ortalama Parlaklık Hatası Bi-Histogram Eşitleme)                                  |
| MMSICHE         | Median-Mean Based Sub-Image-Clipped Histogram Equalization (Medyan Ortalama Tabanlı Kırpılmış Alt Görüntülü Histogram Eşitleme)                    |
| MSE             | Mean Square Error (Ortalama Karesel Hata)                                                                                                          |
| MSEC            | Mobile Snapshots in Extreme Conditions Veri Kümesi                                                                                                 |
| MSR             | Multi-Scale Retinex (Çok Ölçekli Retineks)                                                                                                         |
| MT              | Metropolis Teoremi                                                                                                                                 |
| NCC             | New Color Channel (Yeni Renk Kanalı)                                                                                                               |
| NCC-PLM         | New Color Channel Driven Pyhsical Lighting Model (Yeni Renk Kanalı Odaklı Fiziksel Aydınlatma Modeli)                                              |
| NIQE            | Natural Image Quality Evaluator (Doğal Görüntü Kalitesi Değerlendiricisi)                                                                          |
| NLIEE           | No-Reference Low-Light Image Enhancement Evaluation (Referanssız Düşük Işık Görüntü İyileştirme Değerlendirmesi)                                   |
| NPE             | Naturalness Preserved Enhancement Veri Kümesi                                                                                                      |
| PASCAL VOC      | Pattern Analysis Statistical Modelling and Computational Learning Visual Object Classes Veri Kümesi                                                |
| PIQE            | Perception-Based Image Quality Evaluator (Algıya Dayalı Görüntü Kalitesi Değerlendiricisi)                                                         |
| PNAR            | Poisson Noise-Aware Retinex (Poisson Gürültüsüne Duyarlı Retineks)                                                                                 |

|               |                                                                                                                                    |
|---------------|------------------------------------------------------------------------------------------------------------------------------------|
| PSNR          | Peak Signal-to-Noise Ratio (Tepe Sinyal-Gürültü Oranı)                                                                             |
| RAM           | Random Access Memory (Rastgele Erişimli Bellek)                                                                                    |
| RCTNet        | Representative Color Transformation Network (Temsili Renk Dönüşümü Ağı)                                                            |
| RDGAN         | Retinex Decomposition based Generative Adversarial Network (Retineks Ayırıştırma Tabanlı Üretken Çekişmeli Ağ)                     |
| RDN           | Residual Dense Network (Artık Yoğun Ağ)                                                                                            |
| RDNet         | Retinex Decomposition Network (Retineks Ayırıştırma Ağı)                                                                           |
| RELLISUR      | Real Low-Light Image Super Resolution Veri Kümesi                                                                                  |
| ResNet        | Residual Network (Artık Ağ)                                                                                                        |
| RetinexFormer | Retinex-Based Transformer (Retineks Tabanlı Dönüştürücü)                                                                           |
| RMSHE         | Recursive Mean-Separate Histogram Equalization (Özyinelemeli Ortalama-Ayırma Histogram Eşitleme)                                   |
| RNN           | Recurrent Neural Network (Yinelemeli Sinir Ağı)                                                                                    |
| ROF           | Rudin-Osher-Fatemi                                                                                                                 |
| RRDNet        | Robust Retinex Decomposition Network (Gülbüz Retineks Ayırıştırma Ağı)                                                             |
| RUAS          | Retinex-Inspired Unrolling with Cooperative Prior Architecture Search (Retineks Esinli Açılım ile İşbirlikçi Önsel Mimari Araması) |
| SCI           | Self-Calibrated Illumination (Öz-Kalibreli Eden Aydınlatma)                                                                        |
| SGMNet        | Seyrek Gradyan Minimizasyon Ağı (Sparse Gradient Minimization Network)                                                             |
| SICE          | Single Image Contrast Enhancement Veri Kümesi                                                                                      |
| SID           | See In the Dark Veri Kümesi                                                                                                        |
| SRIE          | Structure-Revealing Image Enhancement (Yapı Ortaya Çıkaran İyileştirme Ağı)                                                        |
| SSDA          | Stacked Sparse Denoising Autoencoder (Seyrek Gürültü Giderme Otokodlayıcı)                                                         |
| SSDHE         | Segment Selective Dynamic Histogram Equalization (Bölüt Seçici Dinamik Histogram Eşitleme)                                         |
| SSIF          | Smoothing-Sharpening Image Filter (Keskinleştirme-Yumuşatma Görüntü Filtresi)                                                      |
| SSIM          | Structural Similarity Index Measure (Yapısal Benzerlik İndeksi Ölçümü)                                                             |

|                  |                                                                                  |
|------------------|----------------------------------------------------------------------------------|
| SSR              | Single-Scale Retinex (Tek Ölçekli Retineks)                                      |
| STRR             | Structure and Texture Revealing Retinex (Yapı ve Dokuyu Ortaya Çıkaran Retineks) |
| TBEFN            | Two-Branch Exposure-Fusion Network (İki Dallı Pozlama Füzyon Ağı)                |
| UCID             | Uncompressed Color Image Database (Sıkıştırılmamış Renkli Görüntü Veritabanı)    |
| U-Net            | U-şekilli Evrişimsel Sinir Ağı                                                   |
| URetinex-Net     | Retinex-Based Deep Unfolding Network (Retineks Tabanlı Derin Açılım Ağı)         |
| VE-LOLCap        | Vision Enhancement in Low-Light Condition Capture Veri Kümesi                    |
| VE-LOL-H         | Vision Enhancement in Low-Light Condition High-Level Veri Kümesi                 |
| VE-LOL-L         | Vision Enhancement in Low-Light Condition Low-Level Veri Kümesi                  |
| VE-LOLSyn        | Vision Enhancement in Low-Light Condition Synthetic Veri Kümesi                  |
| VIT              | Vision Transformer (Görü Dönüştürücü)                                            |
| VV               | Visual Visibility Veri Kümesi                                                    |
| Zero-DCE         | Zero-Reference Deep Curve Estimation (Sıfır Referanslı Derin Eğri Tahmini)       |
| $(Y')^E$         | İyileştirilmiş $Y'$ bileşeni                                                     |
| $\ \cdot\ _p$    | P-norm operatörü                                                                 |
| $A^{GC}$         | Gama düzeltme uygulanmış yaklaşıklık görüntüsü                                   |
| $D^{GC}$         | Gama düzeltme uygulanmış detay görüntüsü                                         |
| $E_0$            | Gürültü giderilmiş görüntü                                                       |
| $E_{EL}$         | Çevresel ışık tahmin filtresinin çıkışı                                          |
| $I_{\max}$       | Giriş görüntüsünün maksimum yoğunluk değeri                                      |
| $I_E$            | İyileştirilmiş görüntü                                                           |
| $I^{GC}$         | Gama düzeltme uygulanan giriş görüntüsü                                          |
| $I^{OB}$         | Turuncu-mavi karşıtlık bilgisini içeren bileşen                                  |
| $I_{final}^{OB}$ | Nihai $I^{OB}$ bileşeni                                                          |
| $L^{EL}$         | Çevresel aydınlatma                                                              |
| $L_D$            | Ayrıştırma seviyesi                                                              |
| $L_R$            | Aydınlatma bileşeni                                                              |
| $Q_{final}$      | Nihai Q bileşeni                                                                 |

|             |                                          |
|-------------|------------------------------------------|
| $R_R$       | Yansıma bileşeni                         |
| $S_D$       | SSIF ile elde edilen yaklaşıklık katmanı |
| $S_R$       | Retineks ayrışımı için giriş görüntüsü   |
| $V^E$       | İyileştirilmiş V bileşeni                |
| $Y'$        | Logaritmik Y bileşeni                    |
| $Y^E$       | İyileştirilmiş Y bileşeni                |
| $Y_{final}$ | Nihai Y bileşeni                         |
| $a_i$       | Filtre girişi ağırlık katsayısı          |
| $b_k$       | Filtre çıkışı ağırlık katsayısı          |
| $c_1$       | Pozitif parametre                        |
| $c_2$       | Pozitif parametre                        |
| $c_G$       | Gauss çevre ölçeği                       |
| $e^{l^L}$   | Tahmin edilen aydınlatma bileşeni        |
| $e^{r^R}$   | Tahmin edilen yansıma bileşeni           |
| $k_G$       | Ölçek numarası                           |
| $l^R$       | Logaritmik yansıma bileşeni              |
| $(m, n)$    | Piksel lokasyonu                         |
| $r_L$       | Yaklaşık aydınlatma bileşeni             |
| $r^R$       | Logaritmik yansıma bileşeni              |
| $r_R$       | Yaklaşık yansıma bileşeni                |
| $r_{k'}$    | Gri değer seviyesi                       |
| $s^I$       | Logaritmik giriş görüntüsü               |
| $s_{max}$   | Transfer fonksiyonunun maksimum değeri   |
| $t_{BCP}$   | Parlak kanal önselinin çıkışı            |
| $t^{LSAR}$  | Başlangıç ışık saçılım zayıflama oranı   |
| $\alpha_L$  | Parlaklık orantı katsayısı               |
| $\beta_C$   | Renklilik faktörü                        |
| $\gamma_l$  | Gama düzeltme faktörü matrisi            |
| $\lambda_G$ | Gauss normalizasyon faktörü              |
| $\mu_A$     | Yaklaşıklık katmanının ortalaması        |
| $\mu_f$     | Test görüntüsünün ortalaması             |
| $\mu_g$     | Kesin referans görüntüsünün ortalaması   |
| $\mu_V$     | V bileşeninin ortalaması                 |

|                |                                                           |
|----------------|-----------------------------------------------------------|
| $\sigma_f^2$   | Test görüntüsünün varyansı                                |
| $\sigma_g^2$   | kesin referans görüntüsünün varyansı                      |
| $\sigma_{fg}$  | Test görüntüsü ile kesin referans görüntüsünün kovaryansı |
| $\sigma_r$     | Aralık çekirdeği                                          |
| $\sigma_s$     | Uzamsal çekirdek                                          |
| $\omega_{k_G}$ | Gauss ölçeği ağırlık katsayısı                            |
| $\omega_j$     | Detay iyileştirme katsayısı                               |
| $[a, b]$       | Giriş görüntüsünün gri seviye aralığı                     |
| $[c, d]$       | İyileştirilmiş görüntünün gri seviye aralığı              |
| *              | Evrişim operatörü                                         |
| $\odot$        | Eleman bazlı çarpım                                       |
| $\nabla$       | Gradyan operatörü                                         |
| $\in$          | Elemanıdır                                                |
| $\Sigma_p$     | Doğal görüntü modelinin kovaryans matrisi                 |
| $\Sigma_d$     | Test görüntüsünün kovaryans matrisi                       |
| $\exp(.)$      | Doğal üstel fonksiyon                                     |
| $\log$         | Logaritma                                                 |
| $\max(.)$      | Maksimum değer operatörü                                  |
| $\min(.)$      | Minimum değer operatörü                                   |
| sn             | Saniye                                                    |
| $\Omega$       | Yerel bölge                                               |
| $A$            | Yaklaşıklık katmanı                                       |
| $B$            | Mavi kanal                                                |
| $BLS(.)$       | İki yanlı filtre operatörü                                |
| $C_1^{SA}$     | Pozitif sabit                                             |
| $CLAHE[.]$     | CLAHE operatörü                                           |
| $D$            | Detay görüntüsü                                           |
| $D_{sk}$       | Belirli bir blok için bozulma skoru                       |
| $E$            | Amaç fonksiyonu                                           |
| $F$            | Gauss çevre fonksiyonu                                    |
| $G$            | Yeşil kanal                                               |
| $H$            | Renk bileşeni                                             |
| $I$            | Giriş görüntüsü                                           |


|           |                                              |
|-----------|----------------------------------------------|
| $INT(.)$  | En yakın tam sayıya yuvarlama operatörü      |
| $K$       | Merkezi çevre fonksiyonu sayısı              |
| $M$       | Görüntü genişliği                            |
| $MT(.)$   | Metropolis teorem operatörü                  |
| $N$       | Görüntü yüksekliği                           |
| $N_{SA}$  | Uzamsal aktif blok sayısı                    |
| $NC$      | Yeni renk kanalı                             |
| $NP$      | Yeni renk kanalı önseli                      |
| $P(k')$   | Orijinal görüntü                             |
| $Q$       | Mor-yeşil karşıtlık bilgisini içeren bileşen |
| $R$       | Kırmızı kanal                                |
| $S$       | Doygunluk bileşeni                           |
| $SSIF(.)$ | SSIF operatörü                               |
| $T$       | Sıcaklık katsayısı                           |
| $V$       | Değer bileşeni                               |
| $Y$       | Parlaklık bileşeni                           |
| $c(k')$   | Kümülatif Dağılım Fonksiyonu                 |
| $e$       | Euler sayısı                                 |
| $f$       | Test görüntüsü                               |
| $g$       | Kesin referans görüntüsü                     |
| $j$       | Ayrıştırma seviyesi değeri                   |
| $j'$      | Piksel lokasyonu                             |
| $k$       | Dönüşüm fonksiyonunun eğimi                  |
| $k'$      | Gri seviye değeri                            |
| $l$       | Gri seviye sayısı                            |
| $mean(.)$ | Ortalama operatörü                           |
| $r$       | Yarıçap                                      |
| $s$       | Ölçek                                        |
| $v_p$     | Doğal görüntü modelinin ortalama vektörü     |
| $v_d$     | Test görüntüsünün ortalama vektörü           |
| $v + 1$   | Logaritma tabanı                             |
| $x$       | Filtre girişi                                |
| $y$       | Filtre çıkışı                                |
| $\alpha$  | Kırpma faktörü                               |

|               |                                    |
|---------------|------------------------------------|
| $\beta$       | Kırpma limiti                      |
| $\gamma$      | Gama dönüşüm sabiti                |
| $\gamma$      | Gama düzeltme faktörü              |
| $\varepsilon$ | Küçük bir sabit                    |
| $\varepsilon$ | Epsilon                            |
| $\theta$      | Karartma faktörü                   |
| $\kappa$      | Kappa                              |
| $\lambda$     | Gri değer ayar sabiti              |
| $\mu$         | Giriş görüntüsünün ortalama değeri |
| $\xi$         | Soğutma katsayısı                  |



## 1. GİRİŞ

Bilgisayarlı görü teknolojisinin hızla gelişmesi ile birlikte, görüntü işleme sistemleri endüstriyel üretim (Hao et al., 2017), video izleme (Ahmed and Jeon, 2021), akıllı ulaşım (Ge et al., 2023) ve uzaktan algılama (Kaplan, 2018) gibi birçok alanda kullanılmaktadır. İşlenecek olan görüntülerin yakalanma süreçlerinde bazı faktörler kontrol edilemeyen bozulmalara sebep olmaktadır. Özellikle iç mekan, bulutlu günler ve gece gibi zayıf aydınlatma koşullarında nesnelerden yansıyan ışık miktarını azaltmaktadır. Bu nedenle, belirtilen koşullarda yakalanan görüntülerin kalitesi, renk bozulmaları, düşük aydınlık ve gürültü gibi sebeplerle ciddi şekilde düşebilmektedir. (Park et al., 2018). Ayrıca, görüntü saklama, dönüştürme ve aktarma gibi işlemlerden sonra bu tür düşük aydınlıklı görüntülerin kalitesi daha da düşmektedir. Düşük aydınlık, aydınlatma koşullarının normal standardın altında olduğu koşulları temsil etmektedir (Kim et al., 2014). Nispeten zayıf ışıklı bir ortamda yakalanan görüntü genellikle düşük aydınlıklı görüntü olarak kabul edilir (Conde et al., 2016). Ancak pratik uygulamalarda düşük aydınlıklı bir ortamı tanımlayan teorik değerleri belirlemek mümkün olmamıştır. Bu nedenle, her görüntü sensörü üreticisinin kendi değerleri vardır. Düşük aydınlıklı bir ortamı tanımlayan teorik değerlerin kesin olarak belirlenememesine rağmen araştırmacılar düşük aydınlıklı görüntüleri sahip oldukları özelliklere göre bazı sınıflara ayırmıştır. Bu özelliklere göre sınıflandırılan bazı görüntüler Şekil 1.1’de verilmiştir.



**Şekil 1.1.** (a) Düzensiz aydınlatmalı görüntü, (b) arkadan aydınlatmalı görüntü, (c) ekstra karanlık görüntü, (d) düşük pozlamalı görüntü, (e) gürültülü görüntü, (f) yerel düşük aydınlıklı görüntü.

Şekil 1.1.(a)'da, bazı bölgelerin fazla aydınlık, bazı bölgelerin ise fazla karanlık olduğu düzensiz aydınlatmalı (uneven illumination) görüntüye örnek verilmiştir. Işık kaynağının ön plandaki nesnenin arkasında olduğu durumda ön plandaki nesne karanlık, arka plan ise parlak görünür. Bu özelliklere sahip görüntüler arkadan aydınlatmalı (backlit) görüntü olarak adlandırılır. Arkadan aydınlatmalı görüntü Şekil 1.1.(b)'de sunulmuştur. Aydınlatmanın yetersiz olduğu iç mekanlarda ve gece koşullarında yakalanan görüntüler düşük parlaklık ve dar bir dinamik aralığa sahiptir. Bu özellikleri sergileyen ekstra karanlık (extra dark) görüntü Şekil 1.1.(c)'de verilmiştir. Görüntü yakalama esnasında sahnedeki ışığın yeterli olmasına rağmen sensörün ulaşan ışık miktarı düşük kalabilir. Bu durumda Şekil 1.1(d)'deki gibi düşük pozlamalı (under exposure) görüntüler elde edilir. Düşük aydınlıklı görüntülerde fiziksel ve elektronik sebeplerden dolayı gürültü yükseltilebilir. Şekil 1.1.(e)'de gürültülü düşük aydınlıklı (noisy low-light) görüntü verilmiştir. Sahneye düşen ışık nesnelerin konumuna bağlı olarak belirli bölgelerde gölge alanlar oluşturur. Bu tarz görüntüler yerel düşük aydınlıklı (local low-light) görüntüler olarak adlandırılır. Şekil 1.1.(f)'de yerel düşük aydınlıklı görüntü sunulmuştur.

Zayıf aydınlatma koşullarındaki ortamlarda yakalanan görüntüler düşük parlaklık, düşük karışıklık, dar gri aralık, renk bozulması ve yüksek ölçüde gürültü gibi özellikler sergiler (Aditya et al., 2014). Düşük aydınlıklı görüntülerin piksel değerleri, zayıf aydınlatma nedeniyle alt gri seviyelerde yoğunlaşmaktadır ve gri farkı sınırlıdır. Bu tür görüntülerin maksimum ve minimum gri seviyeleri arasındaki fark normal görüntülere göre daha azdır. Bu özellikler, görüntüdeki detayların ve kenarların ayırt edilmesini zorlaştırmaktadır. Araştırmacılar, düşük aydınlıklı ortamdan kaynaklanan bozulmaları gidermek için çeşitli iyileştirme yöntemleri üzerinde durmuşlardır. Bunlardan ilki görüntü edinme donanımını iyileştirmektir (Faramarzpour et al., 2007). Düşük aydınlıklı görüntülerin yüksek kalitede yakalanmasını sağlayan kameraların yapımında profesyonel düşük aydınlık devreleri ve filtreler kullanılması nedeniyle üretim süreçleri oldukça karmaşık bir teknoloji gerektirmektedir. Bazı firmalar ürettikleri düşük aydınlıklı kameraları piyasaya sunmasına rağmen yüksek fiyatları nedeniyle pek ulaşılabilir değildirler. Donanım üzerinde iyileştirme yapmak yerine düşük aydınlıklı görüntülerin yazılım algoritmalarıyla iyileştirilmesi büyük bir esneklik sunmaktadır. Bu sebeple, düşük aydınlıklı görüntülerin sayısal görüntü işleme yoluyla iyileştirilmesi önemli bir

araştırma konusu olmuştur. Ayrıca, görüntülerin kalitesini arttırmak için düşük aydınlıklı görüntü iyileştirme algoritmaları büyük öneme ve pratik değere sahiptir.

### **1.1. Tezin Amacı**

Gerçek dünya senaryolarında, görüntüleme sistemlerinin performansı yetersiz aydınlatma sebebiyle önemli ölçüde azalmaktadır. Bu durum, yakalanan görüntülerde yetersiz karışıklık, düşük görünürlük, istenmeyen gürültü ve renk bozulmaları meydana getirmektedir. Karışıklık, görüntüdeki nesnelerin veya ayrıntıların birbirinden ya da arka plandan ayırt edilebilmesini sağlayan ton farklılığıdır (Ferradans et al., 2011). Düşük karışıklık, detayların ve nesnelerin algılanmasını zorlaştırır. Görünürlük ise görüntüdeki nesnelerin veya detayların bir gözlemci tarafından fark edilmesidir (Caimi et al., 2004). Düşük görünürlük, nesnelerin içerdiği detayların, şekillerinin ve konumlarının fark edilmesini zorlaştırır. Gürültü, görüntünün içerdiği bilgiyi gizleyen ve görüntüde rastgele biçimde oluşan istenmeyen bir durumdur (Bonclet 2009). Görüntüde ayrıntı kaybına ve kalitenin belirgin şekilde düşmesine neden olur. Renk bozulması, görüntüdeki nesnelerin ortam ışığının rengine veya görüntü yakalama sisteminin yetersizliğine bağlı olarak gerçek renginden farklı görünmesidir (Lukac and Plataniotis, 2018). Doğal olmayan renkler, nesne tespiti veya sınıflandırma gibi ileri seviye görüntü işleme uygulamaları için doğru olmayan sonuçların ortaya çıkmasına sebep olabilir.

Bu tez çalışmasındaki temel hedef, aydınlatma koşullarının yetersiz olduğu ortamlarda yakalanan görüntülerin kalitesini ve görünürlüğünü artıran özgün yöntemler geliştirmektir. Bu doğrultuda, düşük aydınlıklı görüntülerin iyileştirilmesi hususunda iki ana hedef üzerine odaklanılmıştır. Bunlardan birincisi düşük aydınlıklı görüntüde renk bozulmalarına sebep olmadan görüntünün aydınlatma bilgisini iyileştirmek iken diğer hedef, görüntünün içerdiği kenar ve detay bilgilerini iyileştirmektir. Bu kapsamda, piksel bazlı yeni yöntemlerle düşük aydınlıklı görüntülerin iyileştirilmesi üzerine özgün yöntemler önerilmiştir.

### **1.2. Literatürde Kullanılan Düşük Aydınlıklı Görüntü İyileştirme Yöntemleri**

Son yıllarda, düşük aydınlıklı görüntülerin iyileştirilmesi konusunda yapılan çalışmalar giderek daha popüler hale gelmektedir. Araştırmacılar düşük aydınlıklı koşullarda yakalanan farklı görüntüleri iyileştirmek için birçok görüntü işleme algoritması önermişlerdir (Wang et al., 2020). Düşük aydınlıklı bir görüntünün karanlık

alanının gri deęerleri genellikle kktr. Dřk aydınlıklı grnt iyileřtirme algoritmalarının hedefi, grntnn gri deęerlerini ayarlamak iin bir matematiksel forml veya bir filtreleme yntemi tasarlamaktır. Belirtilen bu hedefe ulařmak iin gri seviye dnřm yntemleri, histogram eřitleme yntemleri, Retineks tabanlı yntemler ve derin ğrenme tabanlı yntemler olmak zere drt farklı metodoloji benimsenmiřtir.

### 1.2.1. Gri Seviye Dnřm Tabanlı Yntemler

Dřk pozlama veya yksek pozlama gibi durumlarda, grntlerin gri seviye deęerleri kk bir aralıkla sınırlı olabilir. Bu tip pozlamalara sahip grntler, dřk grnrlk ve detay kaybı gibi sorunlardan muzdariptir. řekil 1.2’de dřk ve yksek pozlamalı grntler ve bu grntlere ait kesin referans grnts verilmiřtir.



**řekil 1.2.** (a) Dřk pozlamalı grnt, (b) yksek pozlamalı grnt, (c) kesin referans grnts.

Gri seviye dnřm uzamsal alan iřleme yntemini esas alan bir grnt iyileřtirme yntemidir (Raji et al., 1998). Bu yntemde, grntnn gri seviye aralıęını deęiřtirmek iin grntnn her pikselinin gri tonlamasını belirli kurallara gre deęiřtirilmesi hedeflenmektedir. Gri seviye dnřm yntemleri doęrusal dnřmler ve doęrusal olmayan dnřmler olarak ikiye ayrılabilir. Doęrusal gri seviye dnřm yntemleri gri seviye aralıęını deęiřtirmek iin doęrusal denklemler kullanır. Doęrusal gri dnřme ait matematiksel ifade Denklem 1.1’de verilmiřtir.

$$I_E(m, n) = k(I(m, n) - a) + c \quad (1.1)$$

Burada,  $(m, n)$  piksel lokasyonunu,  $I(m, n) \in [a, b]$  giriř grntsn,  $I_E(m, n) \in [c, d]$  iyileřtirilmiř grnty ve  $k = \frac{(d-c)}{(b-a)}$  dnřm fonksiyonunun eęimini temsil etmektedir. Dnřm fonksiyonunun eęimine gre drt farklı durum ortaya ıkabilir.

1.  $k > 1$  olması durumunda, görüntünün dinamik aralığı genişler ve düşük görüntü pozlaması sorunu iyileştirilebilir.
2.  $k = 1$  olması durumunda, görüntünün dinamik aralığının boyutu sabit kalırken gri değer aralığı değişir.
3.  $k < 1$  olması durumunda, görüntünün dinamik aralığının boyutu azalmaktadır.
4.  $k < 0$  olması durumunda, görüntünün başlangıçta koyu olan kısımlar parlaklaşırken, aydınlık olan kısımları koyulaşmaktadır.

Görüntünün bazı kısımlarının yeterli görünürlük ve karşıtlığa sahip olduğu durumlarda görüntünün tamamının iyileştirilmesine ihtiyaç duyulmaz. Bu sebeple, sadece ihtiyaç duyulan alanlarda iyileştirme yapılmalıdır. Bu tip senaryolarda parçalı gri seviye dönüşümü uygulanabilir. Parçalı gri seviye dönüşümü iki kategoriye ayrılabilir. İlk durumda, istenilen gri seviye aralığı genişletilirken diğer aralık statik hale getirilir. Bu amaçla, ilgili gri seviye aralığını genişletmek için eğimi 1'den büyük bir dönüşüm fonksiyonu kullanılır. Bu duruma ilişkin matematiksel ifade Denklem 1.2'de verilmiştir.

$$I_E(m, n) = \begin{cases} a & I(m, n) < a \\ c + \frac{d-c}{b-a}(I(m, n) - a) & a \leq I(m, n) \leq b \\ b & I(m, n) > b \end{cases} \quad (1.2)$$

İkinci durumda ise istenilen gri seviye aralığı genişletilirken diğer gri seviyeler bastırılır. Bunun için ilgili gri seviye aralığına eğimi 1'den büyük bir doğrusal dönüşüm uygulanırken diğer gri seviyelere eğimi 1'den küçük doğrusal dönüşüm uygulanarak bastırılır. Bu işleme ait matematiksel ifade Denklem 1.3'te verilmiştir.

$$I_E(m, n) = \begin{cases} \frac{c}{a} I(m, n) & I(m, n) < a \\ c + \frac{d-c}{b-a}(I(m, n) - a) & a \leq I(m, n) \leq b \\ d + \frac{N-d}{M-b}(I(m, n) - b) & b \leq I(m, n) \leq M \end{cases} \quad (1.3)$$

Düşük aydınlıklı görüntülerin iyileştirilmesinde kullanılan dönüşümlerden bir diğeri ise logaritmik dönüşümdür. Logaritmik dönüşüm, görüntüdeki koyu pikselleri genişletir ve parlak pikselleri sıkıştırır. Bu dönüşüme ait matematiksel ifade Denklem 1.4'te verilmiştir.

$$I_E(m, n) = \lambda \log_{v+1}(1 + v \cdot I(m, n)) \quad (1.4)$$

Burada,  $\lambda$  gri değerlerini ayarlamak için kullanılan bir sabiti,  $v + 1$  logaritmanın tabanını temsil etmektedir.

Gama dönüşümü, düşük aydınlıklı görüntülerin iyileştirilmesinde kullanılan başka bir dönüşüm çeşididir. Gama dönüşümüne ait matematiksel ifade Denklem 1.5'te verilmiştir.

$$I_E(m, n) = \lambda(I(m, n) + \varepsilon)^\gamma \quad (1.5)$$

Burada,  $\lambda$  ve  $\gamma$  dönüşüm parametrelerini temsil ederken,  $\varepsilon$  tabanın sıfır olduğu durumlardan kaçınmak için kullanılan küçük bir sabiti temsil etmektedir.  $\gamma < 1$  olduğu durumda, görüntüdeki piksellerin gri seviye değeri artmaktadır. Düşük aydınlıklı görüntülerin iyileştirilmesinde bu parametrenin 1'den küçük değerleri kullanılmaktadır.  $\gamma > 1$  olduğu durumda, görüntünün gri seviye değerleri azalmaktadır.

### 1.2.2. Histogram Eşitleme Tabanlı Yöntemler

Düşük aydınlıklı görüntülere ait histogram genelde düşük gri seviyelerinde dar bir aralığa sahiptir. Histogram eşitleme (HE), görüntünün gri seviye aralığını genişlettiği için düşük aydınlıklı görüntülerin iyileştirilmesinde sıklıkla kullanılmaktadır. HE algoritmasında, giriş görüntüsünün gri seviyelerini değiştirmek için Kümülatif Dağılım Fonksiyonu (Cumulative Density Function, CDF) kullanılır. Böylece, daha düzgün dağılıma sahip gri seviyeleri elde edilir. HE yöntemlerinin temeli, tüm görüntüyü dikkate alarak histogram eşitleme uygulayan Genel Histogram Eşitleme (Global Histogram Equalization, GHE) yöntemidir. GHE'nin aksine, görüntüdeki ayrıntıları iyileştirmek için Yerel Histogram Eşitleme (Local Histogram Equalization, LHE) görüntünün bir bölümünü ele alır. GHE algoritması aşağıdaki gibi ifade edilebilir (Vijayalakshmi et al., 2020).

- Gri değer seviyesi  $r_{k'}$ , gri seviye sayısı  $l$  olarak ayarlanır.
- Orijinal görüntüdeki ( $P(k')$ ) toplam piksel sayısına göre her bir gri seviye değerinin oranı hesaplanır.
- Kümülatif Dağılım Fonksiyonu Denklem 1.6'daki gibi hesaplanır.

$$c(k') = \sum_{k'=1}^l P(k') \quad (1.6)$$

- Dönüştürülen histogram, Denklem 1.7'deki gibi hesaplanır.

$$I_E(k') = INT((l-1)c(k') + 0.5) \quad (1.7)$$

Burada,  $INT(.)$  en yakın tam sayıya yuvarlama operatörüdür. GHE, koyu veya parlak görüntüleri basit ve etkili bir şekilde iyileştirebilir. Ancak bir görüntüdeki düşük aydınlıklı yerel bölgelerin iyileştirilmesi oldukça zordur. Bu sebeple, GHE iyileştirmeye ihtiyaç duyulmayan bölgelerde ayrıntı kaybına sebep olabilir. Bu sorunun üstesinden gelmek için Uyarlanabilir Histogram Eşitleme (Adaptive Histogram Equalization, AHE) önerilmiştir (Pizer et al., 1987). AHE'nin temel fikri, görüntüyü belirli sayıda alt bloğa ayırarak her alt bloğa bağımsız histogram eşitleme uygulamaktır. Ancak detay kaybını önlerken alt bloklardaki gürültü yükseltilebilir. Buradan hareketle, alt bloklardaki gürültünün sınırlandırabildiği CLAHE yöntemi önerilmiştir (Pisano et al., 1998). Aşırı karışıklık artışının önüne geçmek için kırpma limiti kullanılır. Kırpma limiti Denklem 1.8'de verilmiştir.

$$\beta = \frac{M}{N} \left( 1 + \frac{\alpha}{100} (s_{\max} - 1) \right) \quad (1.8)$$

Burada,  $\beta$  kırpma limitini,  $M$  ve  $N$  giriş görüntüsünün genişliği ve yüksekliğini,  $\alpha$  kırpma faktörünü,  $s_{\max}$  transfer fonksiyonunun maksimum değerini temsil etmektedir.

HE tabanlı algoritmalarının çoğu histogramı ve görüntüyü alt görüntülere ayırarak alt görüntülere sırasıyla histogram eşitleme uygular. Kim (1997), giriş görüntüsünün ortalama piksel değerine göre görüntüyü iki alt görüntüye ayıran Parlaklık Koruyan Bi-Histogram Eşitleme (Brightness Preserving Bi-Histogram Equalization, BBHE) yöntemini önermiştir. Alt görüntülere ayırma işleminin ardından bu iki alt görüntüye bağımsız olarak histogram eşitleme işlemi uygulanır. Böylece, belirli ölçüde parlaklık koruması sağlanmış olur.

Wang et al. (1999), görüntüyü eşit iki alt görüntüye ayıran İkili Alt Görüntü Histogram Eşitleme (Dual Sub-Image Histogram Equalization, DSIHE) yöntemini önermiştir. Önerilen yöntem, görüntüyü iki eşit alana ayıran medyan değerini kullanır. Ardından bu iki alt görüntüye bağımsız olarak histogram eşitleme işlemi uygulanır. Böylece belirli ölçüde karışıklık iyileştirmesi sağlanmış olur.

Karışıklık iyileştirmesini arttırmak amacıyla, Chen and Ramli (2003a) Minimum Ortalama Parlaklık Hatası Bi-Histogram Eşitleme (Minimum Mean Brightness Error Bi-Histogram Equalization, MMBEBHE) yöntemini önermiştir. Önerilen yöntem, her bir eşik seviye için Mutlak Ortalama Parlaklık Hatası (Absolute Mean Brightness Error,

AMBE) deęerini hesaplar. Minimum AMBE deęerine gre eřik seviyesi belirlenerek giriř grnts iki alt grntye ayrılır. Alt grntlere baęımsız histogram eřitleme iřlemi uygulanarak ıkıř grnts elde edilir. MMBEBHE, bazı durumlarda karřıtlıęı ařırı iyileřtirdięi iin kenar ve detay bilgilerinin kaybolmasına sebep olabilir.

Grntnn parlaklık bilgisinin korunamadıęı durumların nne gemek amacıyla, Chen and Ramli (2003b) zyinelemeli Ortalama-Ayırma Histogram Eřitleme (Recursive Mean-Separate Histogram Equalization, RMSHE) yntemini nermiřtir. Giriř grntsnn iki alt grntye ayrılmasını temel alan bu yntem, alt grntlere ayırma iřleminin tekrarlanmasıyla dięer yntemlerden ayrılmaktadır. zyineleme derecesinin seimi parlaklık bilgisinin korunması iin olduka nemlidir. RMSHE yntemi, parlaklık bilgisini nemli lde korur ancak detay iyileřtirmede yeterince iyi performans gsteremez.

Dřk aydınlıklı grntler genelde dřk pozlamalı olsa da bazı durumlarda yksek pozlamalı grntler de dřk aydınlıklı kısımlar ierebilir. Singh and Kapoor (2014a), grnty pozlama eřiklerine gre alt grntlere ayıran Pozlamaya Dayalı Histogram Eřitleme (Exposure-Based Histogram Equalization) yntemini nermiřtir. Bu yntemde, giriř grnts pozlama eřiklerine gre alt grntlere ayrıldıktan sonra alt grntlere baęımsız olarak histogram eřitleme uygulanır. Elde edilen sonular, nerilen yntemin etkili řekilde entropi koruması ve karřıtlık iyileřtirmesi sunduęunu gstermiřtir.

Singh and Kapoor (2014b), giriř grntsn medyan ve ortalama parlaklık deęerine gre drt alt grntye ayıran Medyan Ortalama Tabanlı Kırpılmış Alt Grntl Histogram Eřitleme (Median-Mean Based Sub-Image-Clipped Histogram Equalization, MMSICHE) yntemini nermiřtir. Bu alt grntlere baęımsız histogram eřitleme uygulayarak iyileřtirilmiş grnt elde edilir.

Tang and Isa (2014), giriř histogramını medyan deęerine gre iki alt histograma blen Bi-Histogram Eřitlemeye Dayalı Uyarlanabilir Grnt İyileřtirme (Adaptive Image Enhancement based on Bi-Histogram Equalization, AIEBHE) yntemini nermiřtir. nerilen yntemin yenilięi, kırpma sınırlarını semedeki esneklięidir. İyileřtirme oranını kontrol etmek iin histogram kırpma iřlemi gerekleřtirilir.

Grnt iyileřtirmede karřıtlıęın artması, grntlerin doęal grnmn kaybetmesine sebep olabilmektedir. Buradan hareketle, Khan et al. (2014) Blt Seici Dinamik

Histogram Eşitleme (Segment Selective Dynamic Histogram Equalization, SSDHE) yöntemini önermiştir. SSDHE yönteminde öncelikle düşük karışıklığa sahip görüntünün dinamik aralığı genişletilir. Yeni dinamik aralığa sahip görüntünün histogramı medyan değerleri kullanılarak belirli parçalara ayrılır. Bu parçalara histogram eşitleme işleminin ardından yoğunluk normalizasyonu uygulanarak iyileştirilmiş görüntü elde edilir.

### 1.2.3. Retineks Tabanlı Yöntemler

Retineks teorisi, bir nesnenin renginin yansıyan ışığın uzun dalga (kırmızı), orta dalga (yeşil) ve kısa dalga (mavi) yansıtma yeteneği tarafından belirlendiği fikrine dayanmaktadır. Görüntülerin yalnızca belirli bir niteliğini iyileştirebilen geleneksel doğrusal ve doğrusal olmayan yöntemlerin aksine kenar geliştirme, dinamik aralık sıkıştırma ve renk değişmezliği arasında bir denge kurmaktadır. Retineks teorisi, yaygın olarak kullanılan bir görüntü iyileştirme yöntemidir (Land and McCann, 1971). Düşük aydınlıklı görüntülerin iyileştirilmesinde sıklıkla kullanılan Retineks teorisi, giriş görüntüsünün yansıma ve aydınlatma bileşeni olmak üzere iki bileşene ayrıştırılmasına dayanmaktadır (Lee et al., 2015). Retineks algoritmaları, Tek Ölçekli Retineks (Single-Scale Retinex, SSR) (Jobson et al., 1997) ve Çok Ölçekli Retineks (Multi-Scale Retinex, MSR) (Rahman et al., 1996) olmak üzere ikiye ayrılır.

Retineks teorisine göre, bir giriş görüntüsü Denklem 1.9'daki gibi yansıma ve aydınlatma bileşenlerine ayrılmaktadır.

$$S_R(m, n) = R_R(m, n) \cdot L_R(m, n) \quad (1.9)$$

Burada,  $(m, n)$  piksel koordinatlarını,  $S_R(m, n)$  giriş görüntüsünü,  $R_R(m, n)$  yansıma bileşenini ve  $L_R(m, n)$  aydınlatma bileşenini temsil etmektedir. Retineks teorisinin temel amacı, aydınlatmanın etkilerini ortadan kaldırmak veya azaltmak ve nesnenin temel özelliklerini korumaktır. SSR algoritmasıyla yansıma bileşeninin tahmini Denklem 1.10'da verilmiştir.

$$\begin{aligned} r_R(m, n) &= \log S_R(m, n) - \log (F(m, n) * S_R(m, n)) \\ r_R(m, n) &= R_R(m, n) \end{aligned} \quad (1.10)$$

Burada,  $*$  evrişim operatörünü,  $S_R(m, n)$  giriş görüntüsünü,  $R_R(m, n)$  yansıma bileşenini ve  $F(m, n)$  Gauss çevre fonksiyonunu temsil etmektedir. Gauss çevre fonksiyonu Denklem 1.11'deki gibi hesaplanabilir.

$$F(m, n) = \lambda_G e^{\frac{-(m^2 + n^2)}{c_G^2}} \quad (1.11)$$

Burada,  $c_G$  Retineks ölçeğinin derinliğini belirleyen Gauss çevre (komşuluk) ölçeğini,  $\lambda_G$  ise bu ölçeğin normalizasyonunu sağlayan bir faktörü temsil etmektedir. Yukarıdaki formüllerden SSR'nin görüntüdeki piksellerin ve çevresindeki alanın ağırlıklı ortalamasını hesaplayarak görüntünün aydınlatmasını azalttığı anlaşılmaktadır.

Rahman et al. (1996), farklı ölçeklerdeki iyileştirme sonuçlarını bir araya getiren, görüntüdeki yerel ve küresel bilgileri dikkate alan çok ölçekli bir Retineks algoritması önermiştir. MSR'nin temel amacı, farklı ölçeklerdeki birkaç merkezi çevre fonksiyonunu birleştirerek aydınlatma bileşenini tahmin etmektir. MSR, Denklem 1.12'deki gibi ifade edilebilir.

$$r_L(m, n) = \sum_{k_G}^K \omega_{k_G} \{ \log S_R(m, n) - \log (F(m, n) * S_R(m, n)) \} \quad (1.12)$$

Burada,  $K$  merkezi çevre fonksiyonu sayısını temsil etmektedir.  $K = 1$  olması durumunda, MSR algoritması SSR algoritmasına dönüşür.  $\omega_{k_G}$ ,  $k_G$ 'inci ölçeğin ağırlıklandırma katsayısını temsil eder ve Denklem 1.13'teki şartı sağlaması gerekir.


$$\sum_{k_G}^K \omega_{k_G} = 1 \quad (1.13)$$

Bertalmio et al. (2009), uygun bir rastgele değişkenin beklenen değerinin bir çekirdek fonksiyonu ile ağırlıklandırılmasına dayanan bir Çekirdek Tabanlı Retineks (Kernel-Based Retinex, KBR) yöntemi önermiştir. Geleneksel yol tabanlı Retineks uygulamalarından farklı olarak, KBR piksel karşılaştırmalarını komşuluk bölgelerinde gerçekleştirmek için çekirdek fonksiyonlarını kullanır. Böylece, yön bağımlılığı ve yapaylık gibi yol tabanlı yöntemlerde ortaya çıkan sorunlar ortadan kalkmaktadır.

Morel et al. (2010), orijinal Retineks algoritmasını kısmi diferansiyel denklem olarak biçimlendirerek problemi yalnızca bir parametre içeren hızlı bir algoritmaya dönüştürmüştür. Retineks modelindeki yolların simetrik rastgele yürüyüşler olarak kabul edilmesi halinde, Retineks algoritması Neumann sınır koşulları ile tanımlanan ayrık bir Poisson denklemi olarak yeniden biçimlendirilebilir. Bu biçimlendirme, Retineks algoritması için Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) kullanılarak daha

verimli bir hesaplama yöntemi sunar. Deneysel sonuçlar hesaplama maliyetinin önemli ölçüde azaldığını göstermektedir.

Retineks teorisinin tanıtılmasından bu yana birçok görüntü iyileştirme algoritması önerilmiştir. Li et al. (2015) yinelemeli iki yanlı filtreye dayalı yeni bir yöntem önermiştir. Yönteme ait genel çerçeve Şekil 1.3'te verilmiştir.



**Şekil 1.3.** Yinelemeli İki Yanlı Retineks yöntemi (Li et al., 2015).

Yöntem dört adımdan oluşmaktadır. İlk olarak, giriş görüntüsüne ait aydınlatma bileşeni tahmin edilir. Ardından, giriş görüntüsü ve aydınlatma bileşeni logaritma alanına aktarılır. Aydınlatma bileşeni giriş görüntüsünden çıkarılarak yansıma bileşeni bulunur. Son olarak yansıma bileşenine histogram eşitleme işlemi uygulanarak iyileştirilmiş yansıma bileşeni elde edilir. Yinelemeli İki Yanlı aydınlatma tahmini Denklem 1.14'te verilmiştir.

$$y_i = \sum_{i=0}^{n-1} (a_i \cdot x_{i-1}) - \sum_{k=1}^n (b_k \cdot y_{i-k}) \quad (1.14)$$

Burada,  $y$  filtre çıkışını,  $x$  filtre girişini,  $a_i$  ve  $b_k$  ağırlık katsayılarını temsil etmektedir.

Fu et al. (2016), giriş görüntüsünde yansıma ve aydınlatma bileşenlerini tahmin etmek için ağırlıklı varyasyonel bir yöntem önermiştir. Önerilen yöntem, yaygın olarak kullanılan varsayımlara dayanarak, düzenleme terimlerine ağırlık vererek Denklem 1.15'teki amaç fonksiyonunu kullanır.

$$E(r^R, l^L) = \|r^R + l^L - s^I\|_2^2 + c_1 \|e^{r^R} \cdot \nabla r^R\|_1 + c_2 \|e^{l^L} \cdot \nabla l^L\|_2^2 \quad (1.15)$$

$r^R \leq 0$  ve  $s^I \leq 1$

Burada,  $c_1$  ve  $c_2$  pozitif parametreleri,  $\|\cdot\|_p$  p-norm operatörünü,  $r^R$  logaritmik yansıma bileşenini,  $l^R$  logaritmik aydınlatma bileşenini,  $s^I$  logaritmik giriş görüntüsünü,  $e^{r^R}$  ve  $e^{l^L}$  tahmin edilen yansıma ve aydınlatma bileşenlerini temsil etmektedir.

Guo et al. (2017), düşük aydınlıklı görüntüleri iyileştirmek için LIME (Low-Light Image Enhancement via Illumination Map Estimation) adını verdikleri basit ve etkili bir yöntem önermiştir. Öncelikle aydınlatma tahmini için R, G ve B kanallarındaki maksimum değerleri bularak her pikselin aydınlatmasını ayrı ayrı tahmin eder. İyileştirme problemini tam olarak çözmek ve hesaplama yükünü azaltmak için arttırılmış Lagrange çarpanı tabanlı bir algoritma önermektedir. LIME, yalnızca aydınlatma bileşenini tahmin ederek, çözüm alanını daraltır ve hesaplama maliyetini azaltır.

Li et al. (2018), gürbüz Retineks modelini kullanan, düşük aydınlıklı görüntü iyileştirme yöntemi önermiştir. Yöntem, aydınlatma ve yansıma bileşenlerini tahmin eder. Amaç fonksiyonunu optimize etmek için arttırılmış Lagrange çarpanı tabanlı alternatif yön minimizasyon algoritması önerilmiştir. Yöntem, düşük aydınlıklı görüntülerin iyileştirilmesinin yanında su altı görüntü iyileştirme, uzaktan algılanan görüntülerin iyileştirilmesi, görüntü bulanıklığı giderme ve sis giderme gibi uygulamalarda da kullanılabilir.

Ren et al. (2020), yansıma haritasındaki gürültüyü bastırmak için düşük derece önseli kullanan LR3M yöntemini önermiştir. Önerdikleri yöntem, düşük derece önselini Retineks ayrıştırma yöntemine uyarlayan ilk çalışmadır. Aydınlatma bileşeni tahmini yapıldıktan sonra yansıma bileşeni üzerinde karışıklık iyileştirmesi ve gürültü bastırma işlemleri yapılır. Yansıma bileşeni üzerinde yapılan işlemlerde düşük derece önseli kullanılmıştır. Yöntem, düşük aydınlıklı görüntü iyileştirmenin yanı sıra düşük aydınlıklı videoların iyileştirilmesinde de kullanılır.

Matin et al. (2020), Parçacık Sürüsü Optimizasyonu için çoklu amaç fonksiyonu sundukları, Retineks tabanlı bir görüntü iyileştirme yöntemi önermiştir. Karşıtlığı arttırmaya odaklanan amaç fonksiyonu kullanıldığında görüntüdeki parlaklığın ve renkliliğin azalması sorunu üzerinde durmaktadır. Giriş görüntüsünün parlaklık, karışıklık ve renkliliğini arttırmak için yeni çoklu amaç fonksiyonu önerilmiştir.

Kong et al. (2021), Poisson Gürültüsüne Duyarlı Retineks (Poisson Noise-Aware Retinex, PNAR) adlı düşük aydınlıklı görüntü iyileştirme yöntemini önermiştir. Önerdikleri yöntem, düşük karşıtlığa sahip görüntülerde karşıtlığı artırırken gürültüyü

etkin bir şekilde gidermek ve dokuları orijinal haline getirmek için Poisson dağılımını kullanır. Ayrıca, farklı ölçeklerdeki yapı bilgisi ve detay bilgisini çıkarmak için yeni bir yapı ve doku kestirim yöntemi önermiştir. Böylece, aydınlatma bilgisi iyileştirilirken detay bilgisi korunmuş ve gürültü giderme sağlanmıştır.

Pan et al. (2022), aydınlık ve karanlık bölgeleri farklı derecelerde iyileştiren Retineks teorisine dayalı bir yöntem önermiştir. Giriş görüntüsüne ait aydınlatma ve yansıma bileşenleri tahmin edilir. Aydınlatma bileşenine Gauss-Laplasyen piramidi ile iyileştirme işlemi uygulanır. İyileştirilmiş aydınlatma bileşeni ve yansıma bileşeni ile birlikte sonuç görüntüsü elde edilir. Deneysel sonuçlar, detay ve renk bilgisinin etkin bir şekilde korunduğunu göstermektedir.

Jia et al. (2023), farklı aydınlatma koşullarındaki düşük aydınlıklı görüntüleri iyileştirmek için yansıma haritasının yeniden ağırlıklandırılabilirdiği Retineks tabanlı bir yöntem önermiştir. Yöntem, karanlık bölgelerde yüksek, aydınlık bölgelerde düşük ağırlıklar kullanarak düzensiz aydınlatmaya sahip düşük aydınlıklı görüntülerde daha doğal ve dengeli sonuçlar üretmektedir. Ayrıca, yansıma, aydınlatma ve ağırlık haritası bileşenleri optimize edilerek gürültü giderilmiş sonuçlar elde edilir.

Li et al. (2024), Yapı ve Dokuyu Ortaya Çıkaran Retineks (Structure and Texture Revealing Retinex, STRR) yöntemini önermiştir. STRR, aydınlatma ve yansıma bileşenlerine ait gradyan dağılımlarındaki farkı hesaplayarak yapı ve doku haritaları oluşturur. Daha sonra bu haritalar kullanılarak aydınlatma ve yansıma bileşenleri optimize edilir. Son olarak, iyileştirilmiş aydınlatma bileşenine görsel olarak daha iyi hale getirmek için gama düzeltmesi uygulanır. Böylece, kenarların ve detayların korunduğu doğal sonuçlar elde edilir.


Veluchamy and Subramani (2025), düşük aydınlıklı görüntülerin iyileştirilmesi için Retineks tabanlı ayrıntı koruyan gürültü bastırma yöntemini önermiştir. Öncelikle, giriş görüntüsüne HSV dönüşümü uygulanarak V bileşeni elde edilir. Daha sonra, V bileşeni yansıma ve aydınlatma bileşenlerine ayrılır. Aydınlatma bileşenine ağırlıklı dönüşüm uygulanarak iyileştirilmiş aydınlatma bileşeni elde edilir. İyileştirilmiş aydınlatma bileşeni ve yansıma bileşeni kullanılarak yeni V bileşeni oluşturulur. Gürültüyü bastırmak ve daha iyi aydınlatma iyileştirmesi elde etmek için sırasıyla iki yanlı filtre ve gama düzeltme işlemi uygulanır. Son olarak, ters HSV dönüşümü ile iyileştirilmiş görüntü elde edilir.

Retineks tabanlı yöntemlerin temel fikri, giriş görüntüsünü aydınlatma bileşeni ve yansıma bileşeni olmak üzere iki bileşene ayırarak nesnenin gerçek görüntüsünü elde etmektir. Retineks yöntemleri görüntünün karşıtlık ve parlaklık bilgilerini iyileştirmenin yanı sıra dinamik aralık sıkıştırma, kenar iyileştirme ve renk dengesi sağlama gibi işlemlerin gerçekleştirilmesini sağlar. Ancak aşırı parlaklık farkına sahip giriş görüntülerinde iyileştirme sonrasında hale etkileri görülebilir. Ayrıca, MSR algoritmaları renk bozulması, kenar keskinleştirmenin yapılamaması ve ani gölge sınırı gibi sorunlardan muzdariptir. Bu tür sorunların giderilmesi için araştırmacılar Retineks tabanlı yöntemler üzerinde çalışmalar yapmaya devam etmektedir.

#### 1.2.4. Derin Öğrenme Tabanlı Yöntemler

Geleneksel görüntü iyileştirme yöntemleri, iyileştirme işlemi ile birlikte gürültüyü artırma, ayrıntı kaybı ve renk bozulması gibi sorunlara sebep olmaktadır. Son yıllarda, derin öğrenme tabanlı yöntemler yüz tanıma (Li et al., 2020), hedef tespiti (Yin et al., 2023) ve otonom sürüş (Omeiza et al., 2021) gibi birçok bilgisayarlı görü uygulamasında kullanılmaktadır. Bilgisayarlı görü alanında gösterdiği yüksek başarılarından dolayı araştırmacılar görüntü iyileştirme uygulamalarında da derin öğrenme tabanlı yöntemleri benimsemiştir. Derin öğrenmeye dayalı düşük aydınlıklı görüntü iyileştirme yöntemi, modelin normal ışık koşulları altındaki görüntülerin özelliklerini öğrenmesine ve düşük aydınlığın görüntü üzerindeki etkisini azaltmasına olanak tanıyan bir tür veri odaklı bir yöntemdir. Düşük aydınlıklı görüntü iyileştirme alanındaki derin öğrenme tabanlı yöntemler; uçtan uca öğrenme yöntemleri, ayrıştırmaya dayalı öğrenme yöntemleri, füzyon tabanlı öğrenme yöntemleri ve denetimsiz öğrenme yöntemleri olmak üzere dört alt başlıkta ele alınabilir.

Uçtan uca öğrenme süreci, tüm parametrelerin birlikte eğitildiği bir derin öğrenme sürecidir (Guo et al., 2023). Derin öğrenmeye dayalı görüntü iyileştirme yöntemlerinde kullanılan en yaygın yapı, kodlayıcı-kod çözücü yapısıdır. Uçtan uca öğrenme yöntemlerine ait temel yapı Şekil 1.4’te verilmiştir.



**Şekil 1.4.** Uçtan uca öğrenme yöntemlerine ait temel yapı.

Lore et al. (2017), Düşük Aydınlik Ağı (Low-light Net, LLNet) ismini verdikleri derin öğrenme tabanlı bir yöntem önermiştir. LLNet, derin sinir ağlarının bir sınıfı olan yığılmış seyrek gürültü giderme otokodlayıcı (Stacked Sparse Denoising Autoencoder, SSDA) kullanır. Önerilen ağın eğitim ve test aşamalarında sentetik görüntülerden oluşan veri kümeleri kullanılmıştır. Düşük aydınlatma koşullarına sahip görüntülerin parlaklık ve karışıklığını iyileştirirken gürültüyü önemli ölçüde azaltır. Derin öğrenme tabanlı mimariler benimsenerek kayda değer sonuçlar elde eden ilk düşük aydınlıklı görüntü iyileştirme algoritmasıdır.

Tao et al. (2017), düşük aydınlıklı görüntülerin içerdiği gürültüyü gidermek için Evrişimsel Sinir Ağı (Convolutional Neural Network, ESA) tabanlı bir model önermiştir. Bu ağ, iyileştirme işleminden önce gürültü giderici bir ön işlem uygular. Ardından, parlak kanal önseli ve çevresel aydınlık tahmin filtresini kullanarak karışıklığı iyileştirilmiş görüntü elde edilir. Bu işleme ait matematiksel ifade Denklem 1.16'da verilmiştir.

$$I(m, n) = E_0(m, n)t_{BCP}(m, n) + E_{EL}(m, n)(1 - t_{BCP}(m, n)) \quad (1.16)$$

Burada,  $I(m, n)$  gürültü giderme uygulanan görüntüyü,  $E_0(m, n)$  çıkış görüntüsünü,  $t_{BCP}(m, n)$  parlak kanal önselinin çıkışını ve  $E_{EL}(m, n)$  çevresel ışık tahmin filtresinin çıkışını temsil etmektedir. Eğitim ve test aşamasında gerçek düşük aydınlıklı görüntüler kullanılmıştır. Önerilen yöntem mevcut yöntemlerle kıyaslandığında, görsel ve nicel açıdan iyi bir iyileştirme performansı sergilemektedir.

Shen et al. (2017), MSR'nin ileri beslemeli ESA'ya eşdeğer olduğunu ortaya koyarak MSR-Net adını verdikleri bir ağ önermiştir. MSR mimarisinden farklı olarak, Gauss evrişim çekirdeklerine yerine evrişim ve aktivasyon fonksiyonu içeren bir katman kullanılmıştır. Ağın eğitim ve test süreçlerinde UCID (Schaefer and Stich, 2003), BSD (Arbelaez et al., 2010) veri kümelerinin yanı sıra Google'dan yapılan aramalar sonucu elde edilen görüntüler kullanılmıştır. Elde edilen sonuçlar önemli derecede parlaklık iyileştirmesi ve detay iyileştirmesi sağlandığını göstermektedir.

Gharbi et al. (2017), düşük aydınlıklı görüntülerin gerçek zamanlı olarak iyileştirildiği ESA tabanlı bir algoritma önermiştir. Önerilen yöntem, giriş görüntüsünün düşük çözünürlüklü versiyonundan düşük seviye özellik çıkarımı yapmaktadır. Çıkarılan bu özellikler tam çözünürlük üzerinde yapılan işlemlerde kullanılmaktadır. Ağın eğitim ve test aşamasında MIT Adobe FiveK (Bychkovsky et al., 2011) veri kümesi

kullanılmıştır. Yapılan deneyler sonucunda, düşük aydınlıklı görüntü iyileştirme işleminin bir akıllı telefon tarafından kısa bir sürede gerçekleştirilebildiği kanıtlanmıştır.

Chen et al. (2018), Tam Evrişimli Ağ (Fully-Convolutional Network, FCN) tabanlı bir düşük aydınlıklı görüntü iyileştirme algoritması önermiştir. Bu çalışmada, Çok Ölçekli Bağlam Toplama Ağı (Context Aggregation Network, CAN) (Chen et al., 2017) ve U-Net (Ronneberger et al., 2015) yapıları karşılaştırılmıştır. Yapılan çalışmalar sonucunda U-Net mimarisi benimsenmiştir. Ayrıca, daha önceki çalışmalardan farklı olarak, kısa pozlamaya sahip düşük aydınlıklı görüntüler ile bu görüntülere karşılık gelen uzun pozlama referans görüntülerinden oluşan bir veri kümesi sunulmuştur. Önerilen ağın eğitim ve test aşamasında SID adıyla sunulan bu veri kümesi kullanılmıştır. Elde edilen sonuçlar, önerilen yöntemin etkili renk koruması ve gürültü giderme sağladığını göstermektedir.

Ren et al. (2019), Yinelemeli Sinir Ağı (Recurrent Neural Network, RNN) kullanan yeni bir hibrit ağ mimarisi önermiştir. Bu yöntemde, giriş görüntüsüne ait içerik özellikleri içerik akışı (content stream) adı verilen birim ile çıkarılır. İçerik akışı birimi, evrişimsel sinir ağı tabanlı bir birimdir. Kenar özellikleri ise RNN tabanlı olan kenar akışı (edge stream) birimden çıkarılmaktadır. Ağın eğitim aşamasında MIT Adobe FiveK veri kümesi, test aşamasında ise sentetik görüntülerden oluşan bir veri kümesi kullanılmıştır. Önerilen yöntem aydınlatma iyileştirmesi açısından diğer yöntemlerden iyi performans göstermektedir. Ancak yeterli renk korumasını sağlayamamaktadır.

Li et al. (2020), derin otokodlayıcı mimarisine dayanan Düşük Aydınlıklı Kodlayıcı Kod Çözücü Ağını (Low-light Encoder-Decoder Network, LLEDNet) önermiştir. Artık Kodlayıcı Kod Çözücü Ağları (Residual Encoder-Decoder Networks, REDNet) tarafından elde edilen iyi sonuçlar sebebiyle yazarlar bu ağ yapısını benimsemişlerdir (Mao et al., 2016). Önerilen ağ, evrişim ve dekonvolüsyon katmanlarından oluşmaktadır. Önerilen ağın eğitim aşamasında BSD500 (Martin et al., 2001) veri kümesi, test aşamasında ImageNet (Deng et al., 2009) veri kümesi kullanılmıştır. Önerilen yöntem, renk koruması ve aydınlatma iyileştirmesi açısından iyi sonuçlar üretememektedir.

Zhang et al. (2020), yüksek kaliteli iyileştirilmiş görüntüler üretmek için Dikkat Tabanlı (Attention-based) (Vaswani, 2017) sinir ağı önermiştir. Kodlayıcı, kod çözücü ve atlama bağlantılarından oluşan ağ U-Net formundadır. Görüntüdeki yerel olmayan

korelasyondan yararlanarak gürültü giderme için Kanal Dikkat Bloğu (Channel Attention Block) kullanılmıştır. Eğitim aşamasında sentetik görüntüler, test aşamasında ise sentetik görüntülere ek olarak SID veri kümesi kullanılmıştır.

Atoum et al. (2020), renk iyileştirme sürecinde daha etkili sonuçlar elde etmek için Renk Bazlı Dikkat Ağını (Color-Wise Attention Network, CWAN) önermiştir. Önerilen ağ, renk iyileştirme işlemi için bir CWAN birimi, parlaklık iyileştirme ve gürültü giderme işlemi için ayrı bir CWAN birimi kullanır. İki birimden elde edilen görüntülerin füzyonu ile birlikte çıkış görüntüsü elde edilir. Eğitim aşamasında SID veri kümesi, test aşamasında ise SID ve PASCAL VOC (Everingham et al., 2015) veri kümeleri kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin görsel olarak kaliteli ve gerçekçi sonuçlar ürettiğini göstermektedir.

Kim et al. (2021), detay kaybı ve sınırlı renk dönüşüm kapasitesinin önüne geçmek amacıyla Temsili Renk Dönüşümü Ağını (Representative Color Transformation Network, RCTNet) önermiştir. Bu ağ, giriş görüntüsüne özel renk dönüşümü yaklaşımı ile iyi bir renk iyileştirme yeteneğine sahiptir. Bu yeteneği sayesinde, düşük aydınlıklı görüntülerin yanı sıra su altı görüntülerde de önemli derecede renk iyileştirmesi sağlar. Elde edilen sonuçlar, önerilen yöntemin sayısal ve görsel açıdan üstün sonuçlar ürettiğini göstermektedir.

Ma et al. (2022), aydınlatma ve yansımayı aynı anda tahmin edebilmek için iki akışlı Bağlam Duyarlı Ayırıştırma Ağını (Context Sensitive Decomposition Network, CSDNet) önermiştir. Önerdikleri mimari sayesinde aydınlatma ve yansıma bileşenleri birbirinden ayrı ve eşzamanlı olarak tahmin edilir. Farklı uzamsal ölçeklerdeki bağlamsal ilişkileri aydınlatma ve yansıma akışlarını birleştiren bir birim sayesinde öğrenir. Pratik uygulamalarda daha hızlı çıkarımlar elde etmek için %98,5 üzerinde parametre azaltma işleminin uygulandığı daha hafif bir versiyonu geliştirilmiştir. Hafif versiyon, CSDNet ile çok yakın performans göstermektedir.


Yang et al. (2023), düşük aydınlık görüntülerin iyileştirilmesi için LightingNet adını verdikleri bir ağ önermiştir. LightingNet, Görü Dönüştürücü (Vision Transformer, VIT) ve tamamlayıcı öğrenme adı verilen iki alt ağdan oluşur. VIT alt ağından gelen yerel özellikler ile tamamlayıcı öğrenme alt ağından gelen genel özellikleri birleştirerek etkin bir iyileştirme performansı sergiler. LightingNet, LOL (Wei et al., 2018) ve SICE (Cai et al., 2018) referanslı veri kümelerinde, ExDark (Loh and Chan, 2019), DICM (Lee et al.,

2013), LIME (Guo et al., 2017) ve MEF (Ma et al., 2015) gibi referanssız veri kümelerinde görsel ve nicel olarak üstün performans göstermiştir.

Wang et al. (2024), aydınlık uyumu, renk doğallığı, detay koruma ve gürültü bastırma olarak tanımlanan dört fiziksel önselin kullanıldığı uçtan uca bir iyileştirme ağı önermiştir. Oluşturulan kayıp fonksiyonu belirtilen dört fiziksel önseli kullanır. Böylece, önerilen model görsel kaliteyi artırarak daha gerçekçi sonuçlar elde eder. Deneysel sonuçlar, çeşitli düşük aydınlık senaryolarında modelin genel performansının yüksek olduğunu ve kullanılan fiziksel önsellerin modelin performansına önemli katkılar sağladığını göstermektedir.

Xie et al. (2025), görüntüye ait genel ve yerel özellikleri uzamsal ve frekans alanında aynı anda işleyen çift dallı bir ağ mimarisi önermiştir. Önerdikleri yöntem, Genel-Yerel Etkileşim Ağı (Global-Local Interaction Network, GLINet) ve Çoklu Pozlamalı Kademeli Karşıtlıklı Düzenleme (Multi-Exposure Progressive Contrastive Regularization, MEPCR) olmak üzere iki temel çerçeve sunar. GLINet, çok seviyeli özellik çıkarımında üstünlük sağlarken, MEPCR yöntemin genelleştirme yeteneğini artırır. Görsel ve nicel sonuçlar, önerilen iki çerçevenin iyileştirme sonuçlarına önemli katkılar sağladığını göstermektedir.

Retineks teorisinin açıkladığı ilham verici modelden esinlenerek, görüntü ayrıştırma fikri ve derin öğrenme algoritmalarının birleştirilmesi üzerine çok sayıda araştırma yapılmaktadır. Ayrıştırma tabanlı öğrenme yöntemleri iki ana adımdan oluşur. İlk olarak, düşük aydınlıklı görüntü ve normal görüntü aydınlatma ve yansıma bileşenlerine ayrıştırılır. Düşük aydınlıklı görüntünün bileşenleri, normal görüntüye ait bileşenlerden öğrenilerek optimize edilebilir. İkinci olarak, bileşenler bir ayarlama birimi tarafından tekrar optimize edilir ve bileşenler birleştirilerek iyileştirilmiş görüntü elde edilir. Ayrıştırmaya dayalı öğrenme yöntemlerine ait temel yapı Şekil 1.5'te verilmiştir.



**Şekil 1.5.** Ayrıştırma tabanlı öğrenme yöntemlerine ait temel yapı.

Li et al. (2018), düşük aydınlıklı görüntüler ile bu görüntülere karşılık gelen aydınlatma haritası arasındaki ilişkiyi tahmin eden, LightenNet adı verilen bir ağ önermiştir. Ağ, belirli görevlere sahip dört adet evrimsel katman içerir. İlk iki katman yüksek aydınlıklı bölgelere odaklanırken, üçüncü katman düşük aydınlıklı bölgelere odaklanmaktadır. Son katman ise aydınlatma haritasını yeniden oluşturur. LightenNet'in avantajı eğitim işleminin kolay olmasıdır. Eğitim ve test aşamasında sentetik görüntüler kullanılmıştır.

Wei et al. (2018), üç alt ağdan oluşan Retinex-Net adı verilen bir ağ önermiştir. Önerdikleri ağ, ayrıştırma, ayarlama ve yeniden yapılandırma olmak üzere üç adımdan oluşur. Giriş görüntüsü Decom-Net ağı ile birlikte yansıma ve aydınlatma bileşenlerine ayrıştırılır. Ayarlama adımında ise Enhance-Net ağı aydınlatma haritasını iyileştirmek için kullanılır. Daha sonra, ayarlanmış aydınlatma ve yansıma bileşenleri eleman bazında çarpma işlemi yoluyla birleştirilerek iyileştirilmiş görüntü elde edilir. Eğitim ve test aşamalarında LOL veri kümesi kullanılmıştır. Elde edilen sonuçlar, aydınlatma ve detaylar üzerinde önemli iyileştirme performansı sağlandığını göstermektedir. Ayrıca, yansıma bileşeni üzerinde yapılan gürültü giderme işlemi ile birlikte görsel olarak tatmin edici sonuçlar elde edilmiştir.

Park et al. (2018), düşük aydınlık seviyesinde iyileştirme ve gürültü azaltma için Retineks teorisine dayalı bir İkili Otokodlayıcı Ağ önermiştir. Yöntem, iyileştirilmiş görüntüyü üç adımda tahmin eder. Öncelikle, yığılı bir otokodlayıcı kullanılarak aydınlatma bileşeni tahmin edilir. İkinci adımda yansıma bileşeni tahmin edilir. Son olarak evrimsel bir otokodlayıcı kullanılarak yansıma bileşeni iyileştirilir. Ağın eğitim ve

test aşamalarında sentetik görüntüler kullanılmıştır. Görsel sonuçlar gürültü azaltma işleminin başarılı bir şekilde gerçekleştirildiğini göstermektedir.

Wang et al. (2018), düşük aydınlık girişi için küresel aydınlatma tahmini yapan, ardından bu tahmine göre aydınlatmayı ayarlayan Küresel Aydınlatma Duyarlı ve Detay Koruyan Ağı (Global Illumination Aware and Detail Preserving Network, GLADNet) önermiştir. Önerdikleri ağın mimarisi ardışık iki adımdan oluşmaktadır. İlk adım, giriş görüntüsünün sabit bir boyuta alt örneklenmesidir. Bu işlemde sonra düşük çözünürlük özellikleri çıkarılarak aydınlatma dağılım tahmini yapılır. İkinci olarak, detay iyileştirme işlemi yapılarak iyileştirilmiş görüntü elde edilir. Detay iyileştirme birimi evrişim ve aktivasyon fonksiyonu katmanlarından oluşur. Ağın eğitim aşamasında sentetik görüntüler kullanılırken, test aşamasında LIME, MEF ve DICM veri kümeleri kullanılmıştır. Elde edilen sonuçlar, iyi bir aydınlatma iyileştirmesi elde edildiğini ve detay koruması sağlandığını göstermektedir.

Zhang et al. (2019), KinD adını verdikleri üç alt ağdan oluşan bir ağ önermiştir. Katman ayrıştırma ağı, görüntüleri yansıma bileşeni ve aydınlatma bileşenine ayrıştırmak için kullanılır. Yansıma iyileştirme ağı, düşük aydınlıklı görüntülerin yansıma haritalarını iyileştirmek için kullanılır. Son olarak, aydınlatma ayarlama ağı ise aydınlatma koşulunu esnek bir şekilde başka bir aydınlatma koşuluna dönüştürmek için kullanılır. Ağın eğitim ve test aşamasında eşleşmiş görüntülerden oluşan LOL veri kümesi kullanılmıştır. Ayrıca, daha objektif bir değerlendirme yapılabilmesi için LIME, NPE (Wang et al., 2013) ve MEF gibi referanssız görüntüler kullanılmıştır. Deneysel sonuçlar, görsel ve nicel olarak tatmin edici sonuçlar elde edildiğini göstermektedir. Zhang et al. (2021), KinD yönteminin gelişmiş bir versiyonu olan KinD++ algoritmasını önermiştir. Gelişmiş versiyon, önceki versiyona kıyasla daha iyi detay iyileştirmesi sunmaktadır.

Wang et al. (2019), düşük pozlamalı görüntüleri iyileştirmek için aydınlatmaya ilişkin yeni bir kayıp fonksiyonu içeren DeepUPE (Underexposed Photo Enhancement using Deep Illumination Estimation) ağını önermiştir. Öncelikle, giriş görüntüsüne alt örnekleme işlemi uygulanır. Daha sonra, alt örneklenmiş görüntüye ait yerel ve küresel özellikler kodlayıcı ağı tarafından çıkarılarak aydınlatma tahmini yapılır. Diğer derin öğrenme tabanlı yöntemlerin aksine, bu ağ görüntü-görüntü eşleşmesi yerine görüntü-aydınlatma eşleşmesi üzerine eğitilmiştir. Eğitim aşamasında MIT Adobe FiveK veri kümesi kullanılmıştır. Görsel sonuçlar, yöntemin renk koruması açısından etkin

performans sergilediğini gösterse de aydınlatma iyileştirmesi açısından tatmin edici sonuçlar elde edilememiştir.

Wang et al. (2019), Retineks Ayırıştırma Tabanlı Üretken Çekişmeli Ağını (Retinex Decomposition based Generative Adversarial Network, RDGAN) önermiştir. Retineks Ayırıştırma Ağı (RDNet), düşük aydınlıklı giriş görüntüsünü aydınlatma ve yansıma bileşenlerine ayırıştırır. Füzyon İyileştirme Ağı (FENet), ayırıştırma işleminden sonra ayarlanan ya da iyileştirilen bileşenleri birleştirerek çıkış görüntüsünü elde eder. Ağın eğitim ve test aşamasında çoklu pozlamalı görüntülerden oluşan SICE veri kümesi kullanılmıştır. Yöntem, görsel ve nicel açıdan tatmin edici sonuçlar üretmiştir.

Huang et al. (2020), dikkat mekanizması ve Retineks'e dayalı bir düşük aydınlıklı görüntü iyileştirme algoritması önermiştir. Bu yöntemde, aydınlatma maske ağı ile birlikte aydınlatma maskesi tahmin edilir. Ardından, aydınlatma haritası ağı, aydınlatma maskesinden aydınlatma haritasını tahmin eder. Aydınlatma haritası ile birlikte ilk iyileştirilmiş görüntü elde edilir. Bu görüntü, düzeltme ağı birlikte tekrar iyileştirilerek çıkış görüntüsü elde edilir. Ağın eğitim ve test aşamalarında sentetik veri kümeleri kullanılmıştır. Elde edilen sonuçlara göre yöntem renk koruması ve aydınlatma iyileştirmesi açısından iyi bir performans sergilemiştir.

Zhu et al. (2020), giriş görüntüsü üç bileşene ayıran RRDNet (Robust Retinex Decomposition Network) adını verdikleri, üç dallı bir evrimsel sinir ağı önermiştir. RRDNet, giriş görüntüsünü yansıma, aydınlatma ve gürültü olmak üzere üç bileşene ayırıştırır. Ardından, aydınlatma bileşeni üzerinde ayarlama yapılır. Giriş görüntüsünden gürültü bileşeni çıkarılır, ardından sonuç aydınlatma bileşenine bölünerek yeni yansıma bileşeni elde edilir. Elde edilen yansıma bileşeni ve ayarlanmış aydınlatma bileşeninden iyileştirilmiş görüntü elde edilir. RRDNet ağının eğitim ve test aşamalarında MEF, LIME, NPE ve DICM veri kümeleri kullanılmıştır. Nicel sonuçlar sadece referanssız veri kümeleri üzerinde karşılaştırmalar içerdiği için nicel sonuçlar üzerinden objektif bir performans değerlendirmesi yapılamamıştır. Dahası, görsel sonuçlar incelendiğinde yöntemin etkin bir aydınlatma iyileştirmesi ve detay iyileştirmesi sağlayamadığı görülmektedir.

Yang et al. (2021), birden fazla alt ağı sahip bir derin öğrenme modeli önermiştir. Yapılan çalışmada, düşük genlikli yapıları kaldırmak ve önemli olan kenar bilgilerini korumak için Seyrek Gradyan Minimizasyon alt ağı (Sparse Gradient Minimization

Network, SGMNet) oluşturulmuştur. Aydınlatmayı ve yansıma haritalarını tahmin etmek için Artık Yoğun Ağ (Residual Dense Network, RDN) yapısına sahip iki alt ağ kullanılır. Önerilen yöntemin test ve eğitim aşamalarında sentetik ve gerçek görüntüler bir arada kullanılmıştır. Görsel ve nicel sonuçlar, yöntemin etkili bir iyileştirme performansı sağladığını göstermektedir.

Liu et al. (2021), Retineks'ten esinlenen RUAS (Retinex-Inspired Unrolling with Cooperative Prior Architecture Search) adı verilen yöntemi önermiştir. RUAS, aydınlatma tahmini ve gürültü giderme için aynı anda tahmin yapabilen işbirlikçi iki seviyeli bir arama stratejisidir. Ayrıca, bu yöntem tüm arama süreci boyunca eşleştirilmiş veya eşleştirilmemiş denetime ihtiyaç duymaz. Önerdikleri ağın eğitim ve test aşamalarında MIT Adobe FiveK ve LOL veri kümeleri kullanılmıştır. Görsel ve nicel sonuçlar, yöntemin aydınlatma iyileştirmesi, detay iyileştirme ve renk dengesi gibi birçok açıdan üstün performans sergilediğini göstermektedir. Ayrıca, çalışma zamanı açısından iyi performans gösteren bir yöntemdir.

Wu et al. (2022), Retineks tabanlı Derin Açılım Ağını (URetinex-Net) önermiştir. URetinex-Net, başlatma, açılım optimizasyonu ve aydınlatma ayarlaması olmak üzere öğrenme tabanlı üç birim içerir. Başlatma birimi giriş görüntüsünü yansıma ve aydınlatma bileşenlerine ayrıştırır. Optimizasyon birimi, optimizasyon işlemini veriye bağlı önsellere uyarlanabilir şekilde derin bir ağa açar. Optimize edilen aydınlatma bileşeni, aydınlatma ayarlama birimi tarafından düzeltilerek sonuç bileşeni elde edilir. Daha sonra düzeltilmiş aydınlatma bileşeni ve optimize edilmiş yansıma bileşeninden iyileştirilmiş görüntü elde edilir. Ağın eğitim ve test aşamalarında MIT Adobe FiveK ve LOL veri kümeleri kullanılmıştır. Görsel ve nicel sonuçlar ışığında, önerilen yöntem düşük aydınlıklı görüntüler üzerinde üstün ve gerçekçi sonuçlar elde etmiştir.

Ma et al. (2022), aydınlatmayı tahmin etmek için ağırlık paylaşımı yapan kademeli bir öğrenme sürecinden oluşan, Öz-Kalibreli Eden Aydınlatma (Self-Calibrated Illumination, SCI) yöntemini önermiştir. Ağ, öz-kalibreli birim ve aydınlatma tahmin biriminden oluşmaktadır. Öz-kalibreli birim haritası, bir sonraki aşamada aydınlatma tahmin biriminin girişi olarak orijinal düşük aydınlık girişine eklenir. Ağın eğitim ve test aşamalarında MIT Adobe FiveK veri kümesi kullanılmıştır. Elde edilen deneysel sonuçlara göre yöntem yeterli aydınlatma iyileştirmesi sağlayamamaktadır. Ancak çalışma süresi açısından literatürdeki yöntemlerle kıyaslandığında en iyi performansı sergilemektedir.


Chen et al. (2023), Retineks ayrıştırma modeline dayanan ayrıştırma ve iyileştirme ağları içeren bir düşük aydınlıklı görüntü iyileştirme çerçevesi önermiştir. Ayrıştırma ağı, giriş görüntüsünü yansıma ve aydınlatma bileşenlerine ayırır. İyileştirme ağı, aydınlatma bileşeni üzerinde iteratif iyileştirme yaparken, yansıma bileşeni üzerinde gürültü giderme işlemi gerçekleştirir. Yöntem, düşük aydınlıklı görüntülerde tatmin edici sonuçlar elde etse de düzensiz aydınlatmaya sahip görüntülerde renk bozulmalarının önüne tamamen geçememiştir.

Liu et al. (2024), sırasıyla ayrıştırma, düzeltme ve ayarlama olmak üzere üç aşamalı bir çerçeve önermiştir. Bu çerçeve, Retineks modeli ile giriş görüntüsünü yansıma ve aydınlatma bileşenlerine ayırır. Ardından, aydınlatma haritası için genel parlaklık parametresi ile yansıma bileşeni için yerel parlaklık parametresiyle düzeltme yapılır. Son aşamada, bu bileşenlere ait ayarlamalar yapılarak iyileştirilmiş görüntü elde edilir. Görsel sonuçlar, aydınlatma iyileştirmesi ve detay koruma açısından önemli katkılar sunulduğunu göstermektedir. Ancak gürültü bastırma açısından güncel yöntemlerin gerisinde kalmaktadır.

Luo et al. (2025), ayrıştırma işlemini çok terimli kısıtlamalarla iyileştiren ayrıştırma tabanlı bir yöntem önermiştir. Ayrıştırma ağı, yeniden oluşturma doğruluğu, yansıma tutarlılığı, aydınlatma düzgünlüğü ve karşılıklı tutarlılık olmak üzere dört temel kısıtlamayı benimser. Ayrıştırma ile elde edilen aydınlatma ve yansıma bileşenleri yeniden oluşturma ağında iyileştirilir. Parlaklığı artırılmış aydınlatma bileşeni ve gürültü giderme uygulanan yansıma bileşeni birleştirilerek nihai iyileştirilmiş görüntü elde edilir. Görsel sonuçlar, önerilen yöntemin aşırı karanlık görüntülerde başarılı sonuçlar ürettiğini göstermektedir. Ancak düşük aydınlıklı görüntü iyileştirmede hala önemli bir araştırma konusu olan gürültü bastırmada tatmin edici sonuçlar elde edilememiştir.

Görüntü füzyonu alanındaki gelişmeler, araştırmacılara görüntü iyileştirme alanında yeni perspektifler kazandırmıştır. Görüntü füzyonunun düşük aydınlıklı görüntü iyileştirme alanında geleneksel yöntemlerle kullanılmaya başlanması füzyon tabanlı öğrenme yöntemlerine bir öncü olmuştur. Görüntü füzyonu, her bir görüntünün önemli bilgilerini koruyan birden fazla görüntüyü birleştirme tekniğidir (Haghighat et al., 2011). Görüntü füzyonu tabanlı yöntemler girdi olarak farklı pozlama koşullarındaki görüntüleri kullanır. Çoklu pozlama birleştirme tabanlı görüntü iyileştirme, görüntünün aydınlatma bilgisinin iyileştirilmesi, ayrıntılarının iyileştirilmesi ve parlaklık bilgisinin

iyileştirilmesi için birden fazla türetilmiş görüntüyü birleştirir. Füzyon tabanlı öğrenme yöntemlerine ait temel yapı Şekil 1.6’da verilmiştir.



**Şekil 1.6.** Füzyon tabanlı öğrenme yöntemlerine ait temel yapı.

Cai et al. (2018), farklı pozlama seviyelerine sahip düşük aydınlıklı görüntüleri iyileştirmek için Tekli Görüntü Karşıtlık İyileştirme (Single Image Contrast Enhancement, SICE) yöntemini önermiştir. Ağ 15 katmandan oluşan basit bir ESA mimarisine sahiptir. Giriş görüntüsü, aydınlatma ve detay bileşenlerine ayrılır. Bileşen iyileştirme ağında bu bileşenler bağımsız olarak iyileştirilir. Ardından iyileştirilen bileşenlerin füzyonuyla yeni bir görüntü elde edilir. Elde edilen görüntü, tüm görüntü iyileştirme ağı ile birlikte tekrar iyileştirilir. Tüm görüntü iyileştirme ağının girdisi ve çıktısının füzyonuyla sonuç görüntüsü elde edilir. Çalışmada, ilk kez farklı pozlama seviyelerine sahip görüntüler ve bu görüntülere karşılık gelen kesin referans görüntülerinden oluşan SICE adlı veri kümesi sunulmuştur. Ağın eğitim ve test aşamalarında bu veri kümesi kullanılmıştır. Yöntem, aydınlatma iyileştirmesi ve detay koruması açısından iyi sonuçlar elde etmesine rağmen gürültü giderme konusunda tatmin edici sonuçlar elde edememektedir.

Yu et al. (2018), pekiştirmeli öğrenme tabanlı DeepExposure ismini verdikleri bir yöntem önermiştir. Önerdikleri yöntem, giriş görüntüsünü bölütleme işlemine tabi tutar. Ardından, bölüt sayısı ve özelliklerine göre farklı pozlanmış görüntüler oluşturulur. Bu görüntülerin füzyonu ile birlikte iyileştirilmiş görüntü elde edilir. DeepExposure ağının eğitim ve test aşamalarında MIT Adobe FiveK veri kümesi kullanılmıştır. Yöntem detay ve renk koruması açısından tatmin edici sonuçlar üretememektedir. Özellikle parlaklığın yüksek olduğu alanlarda aşırı iyileştirmeye sebep olmaktadır.

Lv et al. (2018), üç birimden oluşan ESA tabanlı Çok Dallı Düşük Aydınlıklı İyileştirme Ağını (Multi-Branch Low-light Enhancement Network, MBLEN) önermiştir. Birinci birim giriş görüntüsünün öz niteliklerini çıkararak iyileştirme birimine girdi oluşturur. İyileştirme birimi tüm alt katmanlardan çıktı görüntüleri oluşturur. Bu görüntüler füzyon biriminde birleştirilerek iyileştirilmiş görüntü elde edilir. Ayrıca, önerilen yöntem birimlerin çekirdek boyutlarını ayarlayarak düşük aydınlıklı video iyileştirmeye olanak sağlar. Ağın eğitim ve test aşamasında sentetik veri kümeleri kullanılmıştır. Deneysel sonuçlar, ağın yeterli aydınlatma iyileştirmesi sağladığını göstermektedir. Ancak iyileştirme işlemi bazı detay ve kenarların kaybolmasına sebep olmaktadır.

Cheng et al. (2019), parlak kanal iyileştirme, logaritmik düzeltme ve CLAHE gibi birden fazla temel görüntü iyileştirme yöntemiyle oluşturulan görüntüleri birleştirmek için ESA tabanlı bir yöntem önermiştir. Önerdikleri ağın eğitim ve test aşamalarında sentetik veri kümesi kullanılmıştır. Elde edilen sonuçlar, yöntemin görsel ve nicel açıdan etkili sonuçlar ürettiğini göstermektedir.

Wang et al. (2019), düşük aydınlıklı görüntülerin iyileştirilmesi için UNet tabanlı bir ağ önermiştir. Giriş görüntüsünün öz niteliklerini çıkarmak için bir öz nitelik çıkarma birimi ve bu çok seviyeli öz nitelikleri birleştirmek için bir öz nitelik füzyon birimi tasarlamıştır. Ağın eğitim ve test işlemleri sentetik veri kümeleriyle gerçekleştirilmiştir. Elde edilen bulgular, ağın renk dengesini koruduğunu ve yeterli aydınlatma sağladığını göstermektedir.

Lu and Zhang (2020), İki Dallı Pozlama Füzyon Ağı (Two-Branch Exposure-Fusion Network, TBEFN) adlı yöntemi önermiştir. Ağ, girdi olarak iki dalda da düşük aydınlıklı giriş görüntüsünü kullanır. Daha sonra bu iki çıktı füzyon birimi tarafından birleştirilerek çıkış görüntüsü elde edilir. Eğitim ve test aşamalarında SICE ve LOL veri kümeleri kullanılmıştır. Görsel ve nicel sonuçlar ağın tatmin edici sonuçlar üretemediğini göstermektedir. Ayrıca, az çeşitlilik gösteren karanlık alanlarda aşırı iyileştirmeler gözlemlenmektedir.

Zhu et al. (2020), iki aşamadan oluşan Kenar İyileştirilmiş Çoklu Pozlamalı Füzyon Ağını (Edge-Enhanced Multi-Exposure Fusion Network, EEMEFN) önermiştir. İlk aşamada, oluşturulan görüntüleri farklı aydınlık koşullarında birleştirmek için çoklu pozlama füzyon birimi kullanılır. Ardından, keskin kenarlı görüntüleri iyileştirmek için

füzyon biriminin sonucunda elde edilen görüntü kenar iyileştirme biriminde işlenir. Ağın eğitim ve test aşamalarında SID veri kümesi kullanılmıştır. Görsel sonuçlar incelendiğinde, yöntemin etkili bir gürültü giderme performansı gösterdiği söylenebilir. Ancak renk ve kenar koruması açısından tatmin edici sonuçlar elde edilememiştir.

Jiang et al. (2022), üretken çekişmeli ağ tabanlı Bozunma Geliştirme Üretim Ağı (Degradation-to-Refinement Generation Network, DRGN) adını verdikleri bir yöntem önermiştir. Algoritma, ilk olarak bozunma öğrenimi ve içerik geliştirme için iki adımlı bir üretim ağı uygular. Ardından, hedef bilgileri çok ölçekli işbirlikçi şekilde temsil etmek için çok çözünürlüklü bir birleştirme ağı oluşturur. DRGN yönteminin eğitim ve test aşamalarında LOL veri kümesi kullanılmıştır. Deneysel sonuçlar önerilen yöntemin görsel ve nicel açıdan tatmin edici sonuçlar ürettiğini göstermektedir.

Wang et al. (2022), iki dallı UNet tabanlı ağları benimseyerek Yerel Renk Dağılımları Önseli Ağını (Local Color Distributions Prior Network, LCDPNet) önermiştir. Yöntem, aşırı ve az pozlamanın olduğu bölgeleri iyileştirmek için bir kodlayıcı-kod çözücü mimarisi kullanır. Bu mimari, yerel renk dağılım piramidinden oluşan yerel renk dağılımı gömülü birimini içerir. LCDPNet, eğitim ve test aşamalarında MSEC (Afifi et al., 2021) veri kümesi kullanılmıştır. Deneysel sonuçlar, yöntemin düşük aydınlıklı görüntü iyileştirmede etkili sonuçlar ürettiğini göstermektedir. Dahası, düşük aydınlıklı görüntü iyileştirme yöntemlerin genelinin aksine aşırı pozlamalı görüntülerde iyi sonuçlar üretmektedir.


Tang et al. (2023), düşük aydınlıklı ortamlarda yakalanan kızılötesi ve görünür görüntülerin füzyonu için yeni bir yöntem önermiştir. Düşük aydınlıklı görüntülerdeki aydınlatma bozulmasının önüne geçmek için kızılötesi ve görünür görüntüden gelen tamamlayıcı bilgiler birleştirilir. Ayrıca, füzyon sonucunda görüntüde oluşabilecek renk bozulmalarını minimuma indirmek için renk tutarlılığına dayalı bir kayıp fonksiyonu geliştirilmiştir. Böylece, doğal olmayan renklerin üretilmesinin önüne geçilmiştir. Aşırı karanlık ortamlarda yakalanan görüntülerde, sadece görünür görüntü kullanılan iyileştirme yöntemlerine göre detay ve renk koruması oldukça üstündür.

Chen et al. (2024), ayrıntı kaybı, düşük karışıklık ve renk bozulmasının önüne geçebilmek için kızılötesi ve görünür görüntüleri birleştiren LENFusion adında bir ağ önermiştir. Önerdikleri yöntem ilk olarak, görünür görüntüdeki aydınlatma değerini uyarlanabilir olarak ayarlayarak ilk parlaklık iyileştirmesini yapar. Daha sonra, kızılötesi ve

görünür görüntüden çıkarılan özellik haritalarını birleştirir ve tekrar iyileştirir. Füzyon sonrasında, birleştirilen görüntüye ait aydınlatma bilgisi girişe geri iletilir. Böylece, aşırı veya yetersiz aydınlatma iyileştirmesinin önüne geçilir. Deneysel sonuçlar, LENFusion yönteminin detay zenginliği, yüksek karışıklık ve yüksek aydınlatma iyileştirmesi sağladığını göstermektedir.

Mevcut füzyon yöntemleri, parametre artışı ve optimizasyon kararsızlığı gibi sorunlardan muzdariptir. Shi et al. (2025), düşük aydınlık koşullarında görüntü iyileştirmede tek yöntemi benimseyen yaklaşımların sınırlamalarını ele almak için birden fazla yöntemi entegre eden FusionNet adında bir yöntem önermiştir. FusionNet yöntemi, CIDNet (Yan et al., 2025), RetinexFormer (Cai et al., 2023) ve ESDNet (Yu et al., 2022) modellerini paralel olarak çalıştırıp bunların çıktılarını Hilbert uzayı teorik garantilerine göre doğrusal füzyon işlemine tabi tutar. Yöntem, eğitim süresi, çıkarım hızı, kararlılık ve genelleme kapasitesi açısından diğer yöntemleri geride bırakmıştır. Ayrıca, kapsamlı deneysel değerlendirmeler sonucunda bu yaklaşım zorlu düşük aydınlıklı veri kümelerinde görsel ve nicel olarak üstün performans göstermiştir.

Derin öğrenme tabanlı yöntemlerin dezavantajlarından biri eğitim aşamasında büyük veri kümelerine ihtiyaç duymasıdır. Eğitim işlemi için ise çoğunlukla eşleştirilmiş veri kümeleri tercih edilmektedir. Ancak aynı sahnenin düşük aydınlıklı ve normal aydınlıklı görüntü çiftlerini yakalamak oldukça zordur. Buna ek olarak, bir modeli eşleştirilmiş veri kümeleriyle eğitmek aşırı uyum ve sınırlı genelleme yeteneği gibi sorunlara sebep olabilir. Araştırmacılar, eşleştirilmiş veri kümelerinin yerine eşleştirilmemiş veri kümeleri kullanarak bu sorunların üstesinden gelmeyi hedeflemektedir. Denetimsiz öğrenme tabanlı yöntemlere ait temel yapı Şekil 1.7’de verilmiştir.



**Şekil 1.7.** Denetimsiz öğrenme tabanlı yöntemlere ait temel yapı.

Zhang et al. (2020), maksimum entropi tabanlı Retineks modeline dayalı bir düşük aydınlıklı görüntü iyileştirme algoritması önermiştir. Ağ, dokuz adet evrişim katmanı içeren basit bir yapıdadır. Ayrıca, sadece düşük aydınlıklı görüntüler ile eğitilebilir ve dakika düzeyinde eğitim zamanı gerektirir. Yöntemin eğitim ve test aşamasında LOL veri kümesi kullanılmıştır. Elde edilen sonuçlar incelendiğinde, önerilen yöntem renk koruması, aydınlatma iyileştirmesi ve gürültü giderme açısından iyi performans göstermektedir. Çalışma zamanı olarak etkili sonuçlar vermesi sebebiyle gerçek zamanlı uygulamalar için uygun bir yöntemdir.

Yang et al. (2020), denetimsiz ve denetimli çerçeveleri birbirine bağlamak için yarı denetimli Derin Yinelemeli Bant Ağını (Deep Recursive Band Network, DRBN) önermiştir. DRBN, düşük aydınlıklı görüntü iyileştirme alanında sunulan ilk yarı denetimli modeldir. Önerdikleri yöntemde ilk aşama denetimli modelleri benimseyen yinelemeli bant öğrenmedir. Kabadan inceye bant gösterimi öğrenilir. İkinci aşamada, bant gösterimi, çekişmeli öğrenme yoluyla iyileştirilmiş düşük aydınlıklı görüntünün kalitesini arttırmak için yeniden oluşturulur. Ağın eğitim ve test aşamalarında LOL veri kümesi kullanılmıştır. Yöntem, özellikle gürültü giderme açısından iyi sonuçlar üretmektedir. Ancak bu durum bazı detay bilgilerinin kaybına sebep olmaktadır.

Guo et al. (2020), aydınlık iyileştirmesini görüntüye özgü eğri tahmini olarak formüle eden, Sıfır Referanslı Derin Eğri Tahmini (Zero-Reference Deep Curve Estimation, Zero-DCE) adını verdikleri bir yöntem önermiştir. Zero-DCE, verilen bir giriş görüntüsünü yinelemeli olarak iyileştirmeye en iyi uyan, aydınlık iyileştirme eğrileri kümesini tahmin etmek için tasarlanmıştır. Önerdikleri ağın eğitim ve test aşamalarında SICE veri kümesi kullanılmıştır. Nicel ve görsel sonuçlar, yöntemin kapsamlı bir

kıyaslama ile birlikte iyi sonuçlar ürettiğini göstermektedir. Ancak gürültü giderme ve renk dengesini koruma açısından iyi performans gösterememektedir. Yazarlar, Zero-DCE++ (Li et al., 2021) adını verdikleri hızlandırılmış ve işlem yükü olarak daha hafif olan bir Zero-DCE versiyonu sunmuştur.

Jiang et al. (2021), düşük aydınlıklı ve normal aydınlıklı görüntü çiftleri olmadan eğitilebilen, çekişmeli üretken ağ tabanlı EnlightenGAN yöntemini önermiştir. Bu yöntem, üretici olarak dikkat tabanlı bir UNet ağını benimser. Ayrıca, küresel ve yerel bilgileri yönlendirmek için küresel ayırıcı ve yerel ayırıcı adında ikili ayırıcı kullanır. BDD-100k (Yu et al., 2020), MEF, LIME, NPE ve DICM gibi çeşitli gerçek dünya görüntüleri üzerinde yapılan deneyler, bu tür görüntüleri iyileştirmek için kolayca uygulanabilir olduğunu göstermektedir. Nicel ve görsel sonuçlar, yöntemin gerçek görüntüler üzerindeki iyileştirme performansının tatmin edici düzeyde olduğunu kanıtlamaktadır.

Xiong et al. (2022), aydınlatma iyileştirme ve gürültü bastırma olmak üzere iki aşamalı, çekişmeli üretken ağ tabanlı bir yöntem önermiştir. İlk aşama olan aydınlatma iyileştirme, bir piramit birimiyle (Zhao et al., 2017) giriş görüntüsünün aydınlatma haritasını tahmin eder. Giriş görüntüsünün aydınlatma haritası ile eleman bazlı bölümünden iyileştirilmiş görüntü elde edilir. Gürültü bastırma aşamasında giriş görüntüsü, iyileştirilmiş görüntü ve aydınlatma maskesi kullanılarak Resnet (Liu et al., 2017) bloklarıyla gürültü bastırma işlemini gerçekleştirir. Ağın eğitim aşamasında, EnlightenGAN ağının eğitim prosedürü benimsenmiştir. Test aşamasında ise MIT Adobe FiveK ve LOL veri kümeleri kullanılmıştır. Deneysel sonuçlar, yöntemin renk koruması ve gürültü bastırma açısından üstün performans sergilediğini göstermektedir.

Literatürdeki mevcut yöntemlerin birçoğu düşük pozlama üzerine odaklanmakta ve aşırı pozlama durumlarında tatmin edici performans sergileyememektedir. Nguyen et al. (2023), aşırı pozlama durumunu göz önünde bulunduran ve kademeli kendini iyileştirme fikrine dayanan bir iyileştirme ağı önermiştir. Yöntemin en önemli katkısı sözde kesin referans üretmesidir. Giriş görüntüsü, önceki dönem çıktıları ve referans görüntülerinden bölge bazında en iyi pikseller seçilir. Bu seçim yapılırken ideal parlaklığa olan yakınlık, renk doygunluğu ve yerel karşıtlık değeri gibi parametreler göz önünde bulundurulur. İyileştirme için U-Net tabanlı bir ağ kullanılır. Deneysel sonuçlar, ağın denetimli yöntemlerle rekabet edebilecek düzeyde sonuçlar ürettiğini göstermektedir.

Jiang et al. (2024), eşleşmiş görüntüleri elde etmenin zorlukları ve genelleme yeteneğini kısıtlaması gibi nedenlerden ötürü denetimsiz öğrenmeyi benimseyen LightenDiffusion adını verdikleri yöntemi önermiştir. Yöntem, giriş görüntüsünü yansıma ve aydınlatma bileşenlerine ayıran alt ağ ile birlikte bu bileşenlere iyileştirme işleminin uygulandığı alt ağdan oluşur. Sunulan görsel ve nicel sonuçlar, LightenDiffusion yönteminin denetimsiz öğrenmeyi benimseyen yöntemlere karşı üstün performans sergilediğini gösterse de denetimli öğrenmeyi benimseyen yöntemler ile rekabet edecek düzeyde olmadığını göstermektedir.

Retineks teorisi ile giriş görüntüsünü yansıma ve aydınlatma bileşenlerine ayırtırmak bazı ayırtırma hatalarına sebep olabilir. Wang et al. (2025), sözde Retineks ayırtımına dayanan denetimsiz bir ağ önermiştir. Bu yöntem, klasik Retineks yönteminin aksine sözde aydınlatma haritası tahmin eder. Yerel ve genel bilgiler bir arada kullanılarak aydınlatma haritası çıkarımı daha doğru şekilde yapılır. Ayrıca, yansıma bileşeni elde edilirken bu bileşene gürültü giderme işlemi uygulanır. Geleneksel U-Net modeli yerine gelişmiş mimari olan U-Net++ mimarisi ile birlikte daha etkili sonuçlar üretilmiştir. Yöntem aydınlatma iyileştirmesi açısından üstün performans gösterse de renk koruması açısından literatürdeki diğer yöntemlerden geride kalmaktadır.

### **1.2.5. Diğer Geleneksel Yöntemler**

Düşük aydınlıklı görüntülerin iyileştirilmesinde kullanılan gri seviye dönüşümü, histogram eşitleme, Retineks teorisi ve derin öğrenme gibi yöntemlerin yanı sıra kamera tepki modeli, sanal pozlama, füzyon, atmosferik aydınlatma ve çeşitli önseller sıklıkla kullanılmaktadır. Derin öğrenme tabanlı yöntemlerin aksine, geleneksel yöntemlerin eğitim için çok büyük veri kümelerine ihtiyaç duymamaları, basit yapıda olmaları ve etkili sonuç vermeleri gibi avantajları bu alanda araştırmaların popülerliğini hala korumasını sağlamaktadır.

Ying et al. (2017), düşük aydınlıklı görüntüleri iyileştirmek için kamera tepki modelini kullanan bir yöntem önermiştir. Kamera sensörü ışınımı ve görüntü piksel değeri arasındaki doğrusal olmayan fonksiyona kamera tepki fonksiyonu denir. Çoğu dijital kamera için kameraya düşen ışınım ve görüntü piksel değeri doğru orantılı değildir (Chang and Wu, 2013). Bu yöntem, ışınım ile piksel değeri arasındaki doğrusal olmayan ilişkiyi modelleyerek renk ve parlaklık bozulmasını azaltır. Kamera tepki modeli ve Retineks teoremi birleştirilerek piksellerin daha doğru şekilde ayarlanması

hedeflenmiştir. Deneysel sonuçlar, yöntemin etkili aydınlatma iyileştirmesi sunarken gürültü giderme açısından iyi sonuçlar üretmediğini göstermektedir.

Wang et al. (2019), aydınlatma yansıma modelini kullanan bir uyarlanabilir düşük aydınlıklı görüntü iyileştirme yöntemi önermiştir. İlk olarak, giriş görüntüsü RGB renk uzayından HSV renk uzayına dönüştürülür. V bileşeni üzerinde yansıma tahmini ve iyileştirme yapılır. Ardından, bu görüntüler temel bileşen analizi tabanlı bir füzyon işlemine tabi tutularak V bileşeni yeniden oluşturulur. Görüntünün H ve S bileşenleri üzerinde herhangi bir işlem yapılmaz. Son olarak, ters HSV dönüşümü ile çıkış görüntüsü elde edilir. Elde edilen sonuçlar, yöntemin parlaklık koruması ve renk dengesi açısından iyi sonuçlar ürettiğini göstermektedir. Ancak bazı durumlarda görüntüde var olan gürültü güçlendirilebilir. Deneysel sonuçlar belirli görüntüler üzerinde yapıldığı için yapılan yorumlar tam bir nesnellik sağlayamamaktadır.

Xu et al. (2021), çok ölçekli füzyon tabanlı bir düşük aydınlıklı görüntü iyileştirme algoritması önermiştir. Giriş görüntüsüne ait beş adet yapay çok ölçekli görüntü oluşturulur. Her bir görüntünün Gauss piramidi ve Laplasyen piramidi oluşturularak çok ölçekli füzyon işlemi yapılır. Daha sonra, giriş görüntüsüne ait Y kanalı üzerinde detay iyileştirme işlemi yapılır. Füzyon görüntüsü ve detay bileşeni eleman bazlı çarpım işlemine tabi tutularak çıkış görüntüsü elde edilir. Deneysel sonuçlar, yöntemin parlaklık ve detay koruması açısından etkili sonuçlar ürettiğini göstermektedir.

Jeon and Eom (2022), atmosferik saçılma modeli tabanlı bir düşük aydınlıklı görüntü iyileştirme yöntemi önermiştir. Bu yöntem, iyileştirilmiş görüntüyü elde etmek için altı temel adımı kullanır. Öncelikle, giriş görüntüsüne ait ters görüntü elde edilir. Ardından, ters görüntüye ait atmosferik aydınlık kestirimi yapılır. Kestirilen atmosferik aydınlık ile birlikte ters görüntü normalize edilir. İyileştirme kalitesini arttırmak için doygunluk tahmini yapılır. Ardından, iletim haritası hesaplanarak iyileştirilmiş görüntü elde edilir. Yöntem, düşük aydınlıklı görüntü iyileştirme kalitesi açısından etkili sonuçlar üretmesinin yanı sıra hızlı sonuçlar vererek gerçek zamanlı uygulamalar için bir alternatif olmaktadır.

Wang et al. (2023), giriş görüntüsüne ait sanal pozlama görüntülerini kullanarak düşük aydınlıklı görüntüleri iyileştiren bir algoritma önermiştir. Yöntem, giriş görüntüsüne ait sanal pozlama görüntülerini üretir. Sanal görüntülere ait karşıtlık, doygunluk ve belirginlik gibi özellikleri kullanarak ağırlık haritalarını oluşturur.

Normalize edilen ağırlık haritasına ait görüntüye Gauss piramit ayrışımı, sanal pozlama görüntülerine Laplasyen piramit ayrışımı uygulanır. Her bir sanal görüntüye ait Laplasyen ve Gauss piramit görüntüleri çarpılır. Son olarak, tüm sanal pozlamalara ait sonuç görüntüleri toplanarak iyileştirilmiş görüntü elde edilir. Deneysel sonuçlar, parlaklık koruması ve detay iyileştirme açısından etkili sonuçlar üretildiğini göstermektedir. Ancak görüntüdeki yüksek pozlamalı alanlardaki parlaklığı bastırma konusunda etkili sonuçlar üretememektedir.

Jeon et al. (2024), gama düzeltme önseli kullanan bir düşük aydınlıklı görüntü iyileştirme algoritması önermiştir. Bu yöntem, atmosferik saçılma modelindeki iletim haritasını HSI ve HSV olmak üzere iki renk uzayında tahmin eder. Gama düzeltme önseli, ters düşük aydınlıklı görüntü üzerinde uygulanarak iletim haritasının tahmin edilmesine yardımcı olur. Tahmin edilen iletim haritası ve atmosferik aydınlatma bilgileri kullanılarak iyileştirilmiş görüntü elde edilir. Kapsamlı deneysel sonuçlar, farklı özelliklere sahip düşük aydınlıklı görüntüler üzerinde etkili karışıklık, ayrıntı ve renk iyileştirmesine sahip sonuçların üretildiğini göstermektedir. Ayrıca, aşırı hesaplama yükünü ortadan kaldırarak oldukça hızlı sonuç vermektedir.

Zhou et al. (2025), düşük aydınlıklı görüntüleri iyileştiren HSV renk uzayı temelli bir yöntem önermiştir. Giriş görüntüsü HSV renk uzayına aktarılır. S bileşeni üzerinde görüntü giderme işlemi, V bileşeni üzerinde ise iki yanlı filtreleme işlemleri yapılır. Daha sonra bu bileşenler Bayes füzyonu ile birleştirilir. Füzyon işleminin sonucuna ve orijinal H bileşenine Rudin-Osher-Fatemi (ROF) (Rudin et al., 1992) modeli uygulanır. Son olarak, ters HSV dönüşümü ile iyileştirilmiş görüntü elde edilir. Yöntem, kenar bilgilerinin korunması, detay koruma ve aydınlatma iyileştirmesi açısından tatmin edici sonuçlar üretmiştir.

### 1.3. Tezin Literatüre Katkıları

Bu tez kapsamında, düşük aydınlıklı görüntü iyileştirme için özgün yaklaşımlar sunulmuştur. Önerilen yaklaşımlara ait detaylar maddeler halinde aşağıda verilmiştir.

#### ◆ Keskinleştirme-Yumuşatma Görüntü Filtresine Dayalı Yaklaşım:

- Keskinleştirme-Yumuşatma Görüntü Filtresi (Smoothing-Sharpening Image Filter, SSIF) için çok ölçekli bir ayrıştırma şeması önerilmiştir. Böylece, düşük aydınlıklı görüntü düşük ve yüksek frekanslı bileşenlerine ayrılması sağlanmıştır.

- Karşıtlık Sınırlı Uyarlanabilir Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE) uygulanarak düşük frekanslı katmanının görünürlüğü artırılmıştır ve detay katmanları güçlendirilerek detaylar zenginleştirilmiştir. Bu sayede, gürültü yükseltilmeden daha yüksek görünürlük elde edilmiştir.

◆ Metropolis Teoremine Dayalı Yaklaşım:

- Metropolis teoremi daha önce düşük aydınlıklı görüntü iyileştirme uygulamalarında kullanılmamıştır. Bu teorem, önerilen yaklaşım ile birlikte düşük aydınlıklı görüntü iyileştirme çerçevesine dahil edilmiştir.
- Metropolis teoremi ile birlikte görüntüleri düşük ve yüksek frekans bileşenlerine ayıran çok ölçekli ayrıştırma şeması önerilmiştir.
- Yerel gama düzeltmesi aracılığıyla düşük ve yüksek frekanslı bileşenler ayrı ayrı iyileştirilmiştir. Son olarak, gürültüyü bastırırken düşük aydınlatmayı etkili bir şekilde ele alan, renk restorasyonu için orantılı olarak düzeltilmiş, iyileştirilmiş bir görüntü elde edilmiştir.

◆ Yeni Renk Kanalı Odaklı Fiziksel Aydınlatma Modeline Dayalı Yaklaşım:

- Yeni Renk Kanalı (New Color Channel, NCC) prosedürü düşük aydınlıklı görüntü iyileştirme problemine ilk kez uyarlanmıştır. Yerel yamalardaki ortalama değerleri göz önünde bulunduran bir önsel önerilmiştir.
- Giriş görüntülerinin, ortalama yoğunluk değerlerine göre aşırı karanlık, karanlık ve hafif karanlık olmak üzere üç kategoriye ayrılması önerilmiştir. Bu sayede, farklı gama düzeltme katsayıları ile birlikte aşırı pozlama ve yetersiz görüş sorunları giderilmiştir.
- Düşük aydınlıklı görüntülerdeki gizli detayları ortaya çıkarmak için fiziksel aydınlatma modeli kullanılmıştır. Bu amaçla, düşük aydınlık giriş görüntüsü ve NCC önseli aracılığıyla modelin iki bilinmeyenini olan ışık saçılım zayıflama oranı (ISZO) ve çevresel aydınlık (ÇA) kestirilerek iyileştirilmiş görüntü elde edilmiştir.

◆ Uyarlanabilir Krominans Gama Düzeltmesine Dayalı Yaklaşım:

- Düşük aydınlatma koşullarında görüntü iyileştirme için İki Yanlı Filtre-En Küçük Kareler (Bilateral Filter in Least Squares, BLF-LS) ilk kez kullanılmıştır.
- Giriş görüntüsüne ait Y bileşeninin düşük frekanslı katmanına yerel gama düzeltmesi uygulanarak, bu bileşenin doğal görünümü korunmuştur. Buna ek olarak, CLAHE ile birlikte gürültü artırılmadan Y bileşeninin karşılıklı artırılmıştır. Ayrıca, I ve Q bileşenlerine sonuç görüntüsünün renk dengesini iyileştirmek için yerel gama düzeltme uygulanmıştır.
- Birçok öğrenmeye dayalı yöntemin aksine, yukarıda belirtilen basit ancak etkili adımlarla birlikte yüksek hesaplama maliyeti ve gürültü hassasiyeti gibi sorunlar barındırmayan, görüntünün yapısal ve renk kalitesini iyileştiren bir yaklaşım önerilmiştir.

#### 1.4. Tezin Akışı

Bu tez, dört ana bölümden oluşan sistematik bir akış takip edilerek oluşturulmuştur. Birinci bölüm olan “Giriş” bölümü, düşük aydınlıklı görüntü iyileştirme konusunun önemi ve literatürde düşük aydınlıklı görüntü iyileştirme üzerine yapılan çalışmalar detaylı bir şekilde incelenmiş ve kapsamlı bir literatür özeti sunulmuştur. Ayrıca, tez konusunun literatürdeki güncel yeri ve tez çalışmasının kapsamı hakkında bilgiler sunulmuştur.

“Materyal ve Yöntem” bölümünde, tez kapsamında sunulan özgün yaklaşımlar ve uygulanan prosedürler detaylı bir biçimde sunulmuştur.

“Araştırma Bulguları ve Tartışma” bölümünde, kullanılan veri kümeleri, performans ölçütleri ve karşılaştırmada kullanılan yöntemler ile ilgili bilgiler verilmiştir. Buna ek olarak, gerçekleştirilen deneysel uygulamalar sonucunda elde edilen veriler ve analiz sonuçları sunulmuştur.

“Sonuç ve Öneriler” bölümünde, tez çalışması kapsamında elde edilen sonuçlar ve bu çalışmaların literatüre olan katkısı vurgulanmıştır. Ayrıca, yöntemlerin daha iyi sonuçlar vermesine katkı sağlayacak öneriler ve ileride yapılması planlanan çalışmalar sunulmuştur.

## 2. MATERYAL VE YÖNTEM

Bu bölümde, tez kapsamında düşük aydınlık görüntülerin iyileştirilmesi konusu üzerine önerilen dört farklı yöntem ayrıntılı olarak sunulmuştur. Önerilen yöntemler, literatürdeki mevcut yaklaşımların sınırlılıklarını aşmayı, görsel ve nicel metrikler açısından en iyi sonuçları elde etmeyi amaçlamaktadır. Her bir yöntem, farklı teorik temeller üzerine kurulmuş olup, düşük aydınlıklı görüntülerin parlaklık, karşıtlık, detay koruma ve renk doğruluğu gibi özelliklerini iyileştirmeyi amaçlamaktadır. Bu bağlamda, önerilen her yöntemin temel çalışma prensibi açıklanarak birbirinden ayrıldığı yenilikçi yönler anlatılmıştır.

### 2.1. Önerilen Keskinleştirme-Yumuşatma Görüntü Filtresine Dayalı Düşük Aydınlıklı Görüntü İyileştirme (SSIF)

Bu tez kapsamında geliştirilen yöntemlerden ilki “Keskinleştirme-Yumuşatma Görüntü Filtresine Dayalı Düşük Aydınlıklı Görüntü İyileştirme” bu bölümde anlatılmıştır. Önerilen SSIF yöntemi, düşük aydınlıklı giriş görüntüsünü çok ölçekli SSIF ayrıştırması ile düşük ve yüksek frekanslı bileşenlerine ayrılmıştır. Böylece, görüntüye ait detay ve kaba bilgiler ayrılmıştır. Yüksek görünürlük ve daha iyi aydınlatma iyileştirmesi sağlamak amacıyla düşük frekans bileşenine CLAHE uygulanmıştır. Daha iyi detaylar elde etmek için yüksek frekans bileşeni bir katsayı ile güçlendirilmiştir. Son olarak, iyileştirilen düşük ve yüksek frekans bileşenleri birleştirilerek sonuç görüntüsü elde edilmiştir (Demir and Kaplan, 2023).

#### 2.1.1. SSIF ile Çok Ölçekli Ayrıştırma

SSIF, filtreleme işlemi için yama yarıçapı ( $r$ ), kappa ( $\kappa$ ), epsilon ( $\epsilon$ ) ve ölçek ( $s$ ) olmak üzere dört adet parametre kullanır (Deng et al., 2021). Filtreleme işlemi için daha büyük bir  $r$  değeri daha iyi yumuşatma sonucu üretir. Bu değerin değiştirilmesi her piksel konumunun varyansını etkilediği için keskinleştirme kazancında değişikliğe sebep olur.  $\kappa$  değeri filtrenin keskinleştirme veya yumuşatma kazanıcını kontrol eder.  $\kappa > 1$  olması durumunda, filtre bir keskinleştirme filtresi olarak işlem yaparken,  $\kappa < 1$  olması durumunda ise filtre bir yumuşatma filtresi olarak işlem yapar.  $\kappa = 1$  durumu ise filtreleme olmadığı anlamına gelmektedir. Düzenleme parametresi olan  $\epsilon$  için daha büyük değerlerinin ayarlanması daha düşük karşıtlığa sahip soluk sonuçlar üretir.  $s$  değeri

ise kullanıcı tanımlı bir parametredir. Giriş görüntüsü  $I$  olan bir filtreleme işleminin çıktısı Denklem 2.1'deki gibi verilebilir.

$$S_D^1[I] = SSIF(I) \quad (2.1)$$

Burada,  $SSIF(.)$  SSIF operatörünü ve  $S_D^1$  ilk yaklaşıklık katmanını temsil etmektedir. SSIF'in çok ölçekli ayrıştırılması için Kaplan and Erer (2021)'e benzer bir yöntem izlenmiştir. Daha yüksek seviyelerde yaklaşıklık katmanı elde edebilmek için filtre çıktıları Denklem 2.2'deki gibi tekrar filtrelenmiştir.

$$S_D^j[I] = SSIF(S_D^{j-1}) \quad (2.2)$$


Burada,  $j$  ayrıştırma seviyesini ve  $S_D^0$  giriş görüntüsünü temsil etmektedir. Detay görüntüleri ise Denklem 2.3'teki gibi elde edilmiştir.

$$D^j[I] = S_D^{j-1}[I] - S_D^j[I] \quad (2.3)$$

$L_D$  seviyeye ait ayrıştırma için orijinal görüntü Denklem 2.4'teki gibi yeniden oluşturulabilir.

$$I = \sum_{j=1}^{L_D} D^j[I] + S_D^{L_D}[I] \quad (2.4)$$

İki seviye ayrıştırma ve yeniden oluşturmaya ait akış şeması Şekil 2.1'de verilmiştir.



**Şekil 2.1.** Çok ölçekli SSIF için iki seviyeli ayrıştırma akış şeması.

### 2.1.2. Düşük Aydınlik İyileştirme Şeması

Düşük aydınlıklı görüntü iyileştirme algoritması aşağıdaki gibi özetlenebilir:

- Giriş görüntü RGB renk uzayından HSV renk uzayına dönüştürülerek H, S ve V bileşenleri elde edilmiştir. HSV renk uzayının RGB renk uzayına dönüştürülmesine kadar yapılan tüm işlemler V alt bandına uygulanmıştır.
- Önerilen çok ölçekli SSIF, detay görüntüsü ve aydınlatma görüntüsünü elde etmek için V bileşenine iki seviyeli ayrıştırma uygulanmıştır.
- İyileştirilmiş görüntüde daha yüksek karşıtlık ve görünürlük elde etmek için nihai aydınlatma görüntüsüne CLAHE uygulanmıştır.
- Her ayrıştırma seviyesinin detay görüntüleri, önceden tanımlanan bir iyileştirme katsayısı ile güçlendirilmiştir.
- İyileştirilmiş V bileşeni, güçlendirilmiş detay görüntüleri ve CLAHE uygulanan aydınlatma görüntüsü eklenerek yeniden oluşturulmuştur.
- Giriş görüntüsüne ait H, S bileşeni ve iyileştirilmiş V bileşenine ters HSV dönüşümü uygulanarak nihai iyileştirilmiş görüntü elde edilmiştir.

Önerilen SSIF yöntemine ait sözde kod Tablo 2.1’de verilmiştir.

**Tablo 2.1.** Önerilen SSIF yöntemi ile iyileştirme için sözde kod.

---

**Girdi:**

$I$  : düşük aydınlık giriş görüntüsü,  $r$  : yama yarıçapı,  $\kappa$  : kappa,  $\varepsilon$  : epsilon  
 $S$  : ölçek,  $\beta$  : kırpma limiti

**İşlem:**

*Adım 1:* Giriş görüntüsüne ( $I$ ) HSV dönüşümü uygula

*Adım 2:* V bileşenine Denklem 2.2 ile iki seviye ayrıştırma uygula

*Adım 3:* Aydınlatma görüntüsüne CLAHE uygula

*Adım 4:* Detay görüntülerini Denklem 2.5 ile ağırlıklandır

*Adım 5:* H, S ve iyileştirilmiş V bileşenine ters HSV dönüşümü uygula

**Çıktı:**


İyileştirilmiş görüntü

---

Önerilen SSIF iyileştirme algoritmasına göre iyileştirilmiş görüntü Denklem 2.5’teki gibi elde edilmiştir.

$$I_E = CLAHE[S_D^L] + \sum_{j=1}^L \omega_j D^j[I] \quad (2.5)$$

Burada,  $\omega_j$  detay iyileştirme katsayısını,  $CLAHE[.]$  CLAHE operatörünü ve  $I_E$  nihai iyileştirilmiş görüntüyü temsil etmektedir. İyileştirme prosedürüne ait akış şeması Şekil 2.2’de verilmiştir.



Şekil 2.2. Önerilen SSIF yöntemine ait akış şeması.

## 2.2. Önerilen Metropolis Teoremine Dayalı Pikel Bazında Düşük Aydınlıklı Görüntü İyileştirme (MT)

Bu tez kapsamında geliştirilen yöntemlerden biri olan “Metropolis Teoremine Dayalı Pikel Bazında Düşük Aydınlıklı Görüntü İyileştirme” bu bölümde anlatılmıştır. Önerilen MT yönteminde, giriş görüntüsüne ilk olarak genel gama düzeltme işlemi uygulanmıştır. Daha sonra, düzeltilmiş görüntü HSV renk uzayına dönüştürülmüştür. V bileşeni üzerinde Metropolis Teoremi (MT) tabanlı çok ölçekli ayrıştırma işlemi gerçekleştirilmiştir. Böylece, V bileşeni düşük ve yüksek frekanslı bileşenlerine ayrılmıştır. Ayrıştırma işleminin ardından, düşük ve yüksek frekanslı bileşenlere yerel gama düzeltmesi uygulanarak iyileştirilmiş V bileşeni elde edilmiştir. Son olarak, Yu et al. (2021) önermiş olduğu parlaklık ağırlıklandırma stratejisi benimsenerek nihai iyileştirilmiş görüntü elde edilmiştir (Demir et al., 2024).

### 2.2.1. Metropolis teoremi ile çok ölçekli ayrıştırma

Metropolis teoreminin çıktısı basitçe Denklem 2.6’daki gibi ifade edilebilir.

$$D_1 = MT(I) \quad (2.6)$$

Burada,  $I$  giriş görüntüsünü,  $MT(.)$  Metropolis teorem operatörünü ve  $D_1$  ilk detay katmanını temsil etmektedir. MT ile çok ölçekli ayrıştırma işlemi uygulamak için Kaplan (2023) önermiş olduğu yaklaşıma benzer bir prosedür izlenmiştir. İlk yaklaşıklık

katmanını elde etmek için Denklem 2.7'deki gibi basit bir çıkarma işlemi gerçekleştirilmiştir.

$$A_1 = I - D_1 \quad (2.7)$$

Sonraki seviyelerdeki detay katmanlarını elde etmek için Denklem 2.8'de verildiği gibi yaklaşıklık katmanlarına iteratif olarak MT uygulanmıştır.

$$D_j = MT(A_{j-1}) \quad (2.8)$$


Burada,  $j$  ayrıştırma seviyesini temsil eder ve  $D_0 = 0$ 'dır.  $j$ . seviye yaklaşıklık katmanını Denklem 2.9'daki gibi hesaplanmıştır.

$$A_j = A_{j-1} - D_j \quad (2.9)$$

Ayrıştırma seviyesi  $L_D$  olan bir orijinal görüntünün yeniden yapılandırılması Denklem 2.10'daki gibi formüle edilebilir.

$$I = \sum_{j=1}^{L_D} D_j + A_{L_D} \quad (2.10)$$


İki seviye için ayrıştırma ve yeniden yapılandırmaya ait akış şeması Şekil 2.3'te verilmiştir.



Şekil 2.3. MT ile iki seviyeli ayrıştırma akış şeması.

### 2.2.2. Düşük Aydınlik İyileştirme Şeması

Düşük aydınlık koşullarında iyileştirme için önerilen yonteme ait akış şeması Şekil 2.4'te verilmiştir.



**Şekil 2.4.** Önerilen MT yöntemine ait akış şeması.

İlk olarak, giriş görüntüsüne Denklem 2.11'deki gibi bir gama düzeltme işlemi uygulanmıştır.

$$I^{GC} = I_{\max} \left[ \frac{I}{I_{\max}} \right]^{\gamma} \quad (2.11)$$

Düzeltilen görüntünün giriş görüntüsüne kıyasla daha yüksek karşıtlığa sahip olması beklenmektedir. Böylece, görüntülerin farklı özelliklerini ayırmak için sonuçların daha basit elde edilmesi sağlanmıştır. Düzeltilen görüntü RGB renk uzayından HSV renk uzayına aktarılmıştır. Görüntünün orijinal rengi ve doygunluğunu korumak amacıyla H ve S bileşenleri üzerinde işlem yapılmamıştır. Bu sebeple, kalan tüm iyileştirme işlemleri V bileşenine uygulanmıştır.

V bileşenine çok ölçekli MT ayrıştırma işlemi uygulanarak iki ayrıştırma düzeyi elde edilmiştir. Bu işlem sonucunda, Denklem 2.10 kullanılarak iki detay görüntüsü ( $D_1, D_2$ ) ve bir yaklaşıklık görüntüsü ( $A_2$ ) oluşturulmuştur. Ayrıştırma sonrasında, düşük ve yüksek frekanslı bileşenler farklı özellikler içerdiğinden, bu bileşenlere yerel gama düzeltme işlemi bağımsız olarak uygulanmıştır. Bu bileşenlere uygulanacak olan yerel gama düzeltmesinde her piksel için Denklem 2.12'deki gibi bir gama değeri belirlenmiştir.

$$\gamma_l = (\mu_{A_2})^{A_2} \quad (2.12)$$

Burada,  $\mu_{A_2}$  yaklaşıklık katmanı  $A_2$ 'nin ortalama değeridir. Şekil 2.4'teki düşük frekanslı yerel gama düzeltme adımına karşılık gelen son yaklaşıklık katmanı Denklem 2.13'teki gibi elde edilmiştir.

$$A_2^{GC} = A_{2\max} \left[ \frac{A_2}{A_{2\max}} \right]^{\gamma_l} \quad (2.13)$$

Benzer şekilde, detay bilgilerini içeren yüksek frekanslı bileşenler ise Denklem 2.14'teki gibi elde edilmiştir.

$$D_j^{GC} = D_j \odot \left[ \frac{A_2}{A_{2_{\max}}} \right]^{\gamma_1 - 1} \quad (2.14)$$

Burada,  $\odot$  iki değişkenin eleman bazlı çarpımını temsil etmektedir. İyileştirilmiş V bileşeni, son yaklaşıklık katmanına ayrıştırma katmanlarının eklenmesiyle Denklem 2.15'teki gibi elde edilmiştir.

$$V^E = \sum_{j=1}^2 D_j^{GC} + A_2^{GC} \quad (2.15)$$

Yu et al. (2021) önermiş olduğu parlaklık orantılı yaklaşım benimsenerek nihai iyileştirilmiş görüntü Denklem 2.16'daki gibi elde edilmiştir.

$$I^E = I^{GC} \odot \left( \frac{V^E}{V + \alpha_L} \right) \quad (2.16)$$

$\alpha_L$ , Denklem 2.17'deki gibi elde edilmiştir.

$$\alpha_L = 0,05 \cdot \mu_V \cdot \left( \frac{V^E}{V} \right) \quad (2.17)$$

Burada,  $\mu_V$  V bileşeninin ortalama değeridir. Tüm iyileştirme prosedürü Tablo 2.2'de verilmiştir.

**Tablo 2.2.** Önerilen MT yöntemi ile iyileştirme için sözde kod.

---

**Girdi:**

$I$  : düşük aydınlık giriş görüntüsü,  $T$  : sıcaklık,  $\xi$  : soğutma katsayısı,  $\gamma$  : gama düzeltme katsayısı

**İşlem:**

*Adım 1:* Giriş görüntüsüne ( $I$ ) Denklem 2.11 ile gama düzeltme uygula

*Adım 2:* V bileşenine Denklem 2.10 ile iki seviye ayrıştırma uygula

*Adım 3:* Düşük ve yüksek frekans bileşenlerine Denklem 2.13 ve Denklem 2.14 ile yerel gama düzeltme uygula

---

**Tablo 2.2.** Önerilen MT yöntemi ile iyileştirme için sözde kod (devamı).


*Adım 4:* Nihai iyileştirilmiş görüntüyü elde etmek için Denklem 2.16 ile parlaklık ağırlıklandırmasını uygula

**Çıktı:**

İyileştirilmiş görüntü

### 2.3. Önerilen Düşük Aydınlıklı Görüntü İyileştirme İçin Yeni Renk Kanalı Odaklı Fiziksel Aydınlatma Modeli (NCC-PLM)

Bu tez kapsamında geliştirilen yöntemlerden biri olan “Düşük Aydınlıklı Görüntü İyileştirme İçin Yeni Renk Kanalı Odaklı Fiziksel Aydınlatma Modeli” bu bölümde anlatılmıştır. Önerilen NCC-PLM yönteminde, ilk olarak düşük aydınlıklı görüntüye ortalama yoğunluk değerine göre gama düzeltmesi uygulanmıştır. Ardından, yeni renk kanalı önseli ile ÇA tahmini ve ISZO tahmini yapılmıştır. Tahmin edilen bileşenler ve gama düzeltmesi uygulanmış görüntü ile birlikte çıkış görüntüsü oluşturulmuştur. Düşük aydınlık koşullarında iyileştirme için önerilen yönteme ait akış şeması Şekil 2.5’te verilmiştir (Kucuk et al., 2025).



**Şekil 2.5.** Önerilen NCC-PLM yöntemine ait akış şeması.

#### 2.3.1. Yeni Renk Kanalı Önseli

Yeni renk kanalı önseli aracılığıyla ISZO’yu tahmin etmek için, her pikseli için yeni renk kanalı (Yang et al., 2017) değeri Denklem 2.18’deki gibi hesaplanmıştır.


$$NC_{j'} = 0,299R_{j'} + 0,587G_{j'} + 0,114B_{j'} - \max(R_{j'}, G_{j'}, B_{j'}) + \min(R_{j'}, G_{j'}, B_{j'}) \quad (2.18)$$

RGB renk uzayındaki bir görüntü için,  $\max(R_{j'}, G_{j'}, B_{j'})$  parlak kanalı,  $\min(R_{j'}, G_{j'}, B_{j'})$  karanlık kanalı temsil etmektedir. Her pikselin ışık saçılım zayıflaması sapmasının, parlak ve karanlık kanallar arasındaki farkla temsil edilmesi amaçlanmıştır. Aydınlatmanın yerel tutarlılığını değerlendirmek için merkez pikselin etrafındaki belirli

bir bölgedeki komşu pikseller dikkate alınmıştır. Belirtilen işlem Denklem 2.19'daki gibi ifade edilebilir.

$$NP_{j'} = \text{mean}(NC_{j'}) \quad (2.19)$$

Burada,  $\Omega$  merkezi  $j'$  olan yerel bir bölgeyi,  $NP$  yeni renk kanal önselini temsil etmektedir. Her yerel bölge için kanal değerleri hesaplandıktan sonra,  $NP$  değerini elde etmek için yerel bölgenin maksimum, minimum ve ortalama değerleri kullanılmıştır. Bu değerler ile elde edilen ışık saçılım zayıflama oranlarına ait görüntüler Şekil 2.6'da verilmiştir.



**Şekil 2.6.** Farklı işlemler için ışık saçılım zayıflama oranı tahminleri. Yerel bölge boyutu  $\Omega = 31 \times 31$  ve karartma faktörü  $\theta = 0,2$  olarak ayarlanmıştır.

Şekil 2.6'da gösterildiği gibi maksimum değeri ile yapılan işlem tüm görüntü için makul bir tahmin sağlayamamıştır. Minimum ile elde edilen tahmin haritası, maksimuma göre daha iyi olsa da uzak bölgelerdeki tahmin yetersiz sonuçlar üretmiştir. Şekil 2.6.(d)'de görüldüğü gibi ortalama ile elde edilen zayıflama tahmini en tutarlı tahmin haritasını üretmiştir. Bu sebeple zayıflama oranı tahminlerinde ortalama değerinin kullanılmasına karar verilmiştir.

### 2.3.2. Gama Düzeltme Stratejisi

Düşük aydınlıklı giriş görüntüsüne Denklem 2.20'deki gibi gama düzeltmesi uygulanmıştır.

$$I^{GC} = I_{\max} \left( \frac{I}{I_{\max}} \right)^{\gamma} \quad (2.20)$$

Burada,  $I$  giriş görüntüsünü,  $I_{\max}$  giriş görüntüsünün maksimum yoğunluğunu,  $\gamma$  gama düzeltme faktörünü ve  $I^{GC}$  gama düzeltme sonrası elde edilen görüntüyü temsil etmektedir. Gama düzeltmesi, iyi bir iyileştirme performansı elde etmek için kritik bir öneme sahiptir. Bu nedenle, giriş görüntülerine farklı gama değerleri ile gama düzeltme

uygulayan bir strateji önerilmiştir. Önerilen stratejide, giriş görüntüleri ekstra karanlık, karanlık ve hafif karanlık olmak üzere üç kategoriye ayrılmıştır. Daha sonra, her kategori için farklı gama değerleri belirlenmiştir. Yapılan deneysel çalışmalar, kategorilerin ortalama yoğunluk değerleriyle güçlü bir korelasyona sahip olduğunu göstermektedir. Belirlenen kategorizasyon Tablo 2.3'te verilmiştir.

**Tablo 2.3.** Ortalama yoğunluk değerlerine göre düşük aydınlıklı görüntülerinin kategorilere ayrılması.

| Görüntü kategorisi | Ortalama değer        |
|--------------------|-----------------------|
| Ekstra karanlık    | $\mu \leq 0,25$       |
| Karanlık           | $0,25 < \mu \leq 0,5$ |
| Hafif karanlık     | $\mu > 0,5$           |

Önerilen yeni renk kanalı çevresel aydınlatmayı tahmin etmek için kullanılmıştır.  $NP$  hesaplandıktan sonra, He et al. (2010) açıkladıkları prosedür izlenerek çevresel aydınlatma belirlenmiştir. İlk olarak,  $NP$ 'nin %0,1'lik en üst piksel değerlerinin konumları belirlenmiştir. Ardından, giriş görüntüsünün ilgili konumlardaki yoğunluk değerleri kontrol edilerek en yüksek değerleri çevresel aydınlatma olarak belirlenmiştir.

### 2.3.3. Işık Saçılım Zayıflama Oranı Tahmini ve Yeniden Yapılandırma

Başlangıç ışık saçılım oranını tahmin etmek için Denklem 2.21 kullanılmıştır.

$$t^{LSAR}_{j'} = 1 - \theta NP_{j'} \quad (2.21)$$

Burada,  $\theta$  karartma faktörünü,  $NP$  yeni renk kanalı önselini temsil etmektedir. Karartma faktörünün etkisini gösteren örnekler Şekil 2.7'de verilmiştir.



**Şekil 2.7.** Farklı karartma faktörü değerleri için iyileştirme sonuçları.

Şekil 2.7'de, karartma faktörü arttıkça iyileştirme sonucunun daha koyu hale geldiği görülmektedir. Ayrıca, küçük karartma faktörü değerleri görüntünün bazı


bölgelerinde aşırı pozlanmış sonuçlara sebep olabilir. Blok etkilerini sınırlamak ve daha iyi bir ISZO tahmini için bu bileşene kılavuzlu filtre uygulanmıştır (He et al., 2012). Tahmin edilen bileşenler ile birlikte iyileştirilmiş görüntü Denklem 2.22'deki gibi elde edilmiştir.

$$I_{Ej'} = \frac{I_{j'} - L_{j'}^{EL}}{\max(t_{j'}^{LSAR}, t_0^{LSAR})} + L_{j'}^{EL} \quad (2.22)$$

Burada,  $I_{j'}$  giriş görüntüsünü,  $L_{j'}^{EL}$  çevresel aydınlatmayı,  $t_{j'}^{LSAR}$  ışık saçılım zayıflama oranını,  $I_{Ej'}$  iyileştirilmiş görüntüyü ve  $t_0^{LSAR}$  ise  $t_{j'}^{LSAR}$ 'nin alt sınırını temsil etmektedir.

#### 2.4. Önerilen Düşük Aydınlıklı Görüntü İyileştirme İçin Uyarlanabilir Krominans Gama Düzeltme (ACGC)

Bu tez kapsamında geliştirilen yöntemlerden biri olan “Düşük Aydınlıklı Görüntü İyileştirme İçin Uyarlanabilir Krominans Gama Düzeltme” bu bölümde anlatılmıştır. Önerilen ACGC yönteminde, giriş görüntüsüne gama düzeltme işlemi uygulanmıştır. Ön düzeltme işleminin ardından, görüntü YIQ renk uzayına dönüştürülmüştür. Y bileşeni, BLF-LS kullanılarak yüksek frekans ve düşük frekans bileşenlerine ayrılmıştır. Düşük frekanslı bileşene yerel gama düzeltme ve CLAHE uygulanmıştır. İyileştirilmiş düşük frekanslı bileşen ve yüksek frekanslı bileşenin toplamı ile iyileştirilmiş Y bileşeni elde edilmiştir. Gösterimde karışıklık olmaması için turuncu-mavi karşıtlık bilgisini içeren bileşen  $I^{OB}$  sembolü ile temsil edilmiştir. Daha iyi bir iyileştirme sonucu elde etmek amacıyla  $I^{OB}$  ve Q bileşenlerine yerel gama düzeltme işlemi uygulanmıştır. Sonuç görüntüsü iyileştirilmiş Y,  $I^{OB}$  ve Q bileşenlerine ters YIQ dönüşümü uygulanmasıyla elde edilmiştir. Önerilen yönteme ait genel çerçeve Şekil 2.8'de verilmiştir (Severoglu et al., 2025).



Şekil 2.8. Önerilen ACGC yöntemine ait akış şeması.

#### 2.4.1. İki Yanlı Filtre-En Küçük Kareler ile Ayrıştırma

BLF-LS kullanılarak düşük frekanslı bileşen Denklem 2.23'deki gibi elde edilmiştir.

$$A = BLS(I) \quad (2.23)$$

Burada,  $I$  giriş görüntüsünü,  $BLS(.)$  iki yanlı filtre operatörünü ve  $A$  yaklaşıklık katmanını temsil etmektedir. Yüksek frekanslı bileşen ise Denklem 2.24'teki gibi hesaplanmıştır.

$$D = I - A \quad (2.24)$$

Burada,  $D$  detay katmanını temsil etmektedir. Giriş görüntüsü, detay katmanı ve yaklaşıklık katmanının toplanmasıyla Denklem 2.25'teki gibi elde edilmiştir.

$$I = D + A \quad (2.25)$$

#### 2.4.2. Düşük Aydınlık İyileştirme Şeması

Giriş görüntüsüne gama değeri 0,4545 (Li et al., 2023) olacak şekilde gama düzeltme işlemi Denklem 2.26'daki gibi uygulanmıştır.

$$I^{GC} = I_{\max} \left[ \frac{I}{I_{\max}} \right]^\gamma \quad (2.26)$$

Düzeltilmiş giriş görüntüsü  $I^{GC}$ , YIQ renk uzayına dönüştürülmüştür. Ardından  $Y$  bileşenine Denklem 2.27'deki gibi logaritmik dönüşüm uygulanmıştır.

$$Y' = \log(Y + 1) \quad (2.27)$$

$Y'$  bileşeni, BLF-LS ayrışımına tabi tutularak detay ve yaklaşıklık katmanları elde edilmiştir. Bu işleme ait matematiksel ifadeler aşağıdaki gibidir.

$$A = BLS(Y') \quad (2.28)$$

$$D = Y' - A \quad (2.29)$$

Elde edilen yaklaşıklık katmanını iyileştirmek için bu bileşene yerel gama düzeltmesi uygulanmıştır. Bu amaçla, her piksel için Denklem 2.30'daki gibi bir değer belirlenmiştir.

$$\gamma_l = (\mu_A)^A \quad (2.30)$$

Burada,  $\gamma_l$  her piksel için bir gama değeri içeren matrisi,  $\mu_A$  yaklaşıklık katmanının ortalamasını temsil etmektedir. Düzeltilmiş yaklaşıklık katmanı Denklem 2.31'deki gibi elde edilmiştir.

$$A^{GC} = A_{\max} \left[ \frac{A}{A_{\max}} \right]^{\gamma_l} \quad (2.31)$$

Burada,  $A^{GC}$  düzeltilmiş yaklaşıklık katmanını ve  $A_{\max}$  yaklaşıklık katmanının maksimum yoğunluk değerini temsil etmektedir. Yerel gama düzeltme işleminin ardından, karışıklığı iyileştirmek için CLAHE kullanılmıştır. Karışıklığı iyileştirilmiş yaklaşıklık bileşeni ve detay bileşeni toplanarak iyileştirilmiş  $Y'$  bileşeni Denklem 2.32'deki gibi elde edilmiştir.

$$(Y')^E = D + A^{GC} \quad (2.32)$$

Burada,  $(Y')^E$  iyileştirilmiş  $Y'$  bileşenini temsil etmektedir. Bu bileşene Denklem 2.33'teki gibi üstel dönüşüm uygulanarak iyileştirilmiş  $Y$  bileşeni elde edilmiştir.

$$Y^E = \exp(Y')^E - 1 \quad (2.33)$$

Burada,  $Y^E$  iyileştirilmiş  $Y$  bileşenini temsil etmektedir. Yu et al. (2021), uyguladığı yaklaşım benimsenerek iyileştirilmiş sonuç bileşeni olan  $Y_{final}$  Denklem 2.34'teki gibi elde edilmiştir.

$$Y_{final} = \frac{Y^E}{Y + \alpha_{LP}} \quad (2.34)$$

Parlaklık oranını ifade eden  $\alpha_{LP}$  matrisi Denklem 2.35'teki gibi hesaplanmıştır.

$$\alpha_{LP} = \frac{Y^E}{Y} \quad (2.35)$$

Y bileşeni üzerinde yapılan işlemlerin ardından, krominans bilgisini iyileştirmek amacıyla  $I^{OB}$  ve  $Q$  bileşenlerine Denklem 2.36'daki gibi yerel gama düzeltme işlemi uygulanmıştır.

$$\begin{aligned} I_{final}^{OB} &= I^{OB} \odot \text{Re}\left((I^{OB})^{\beta_C - \gamma_I}\right) \\ Q_{final} &= Q \odot \text{Re}\left(Q^{\beta_C - \gamma_I}\right) \end{aligned} \quad (2.36)$$

Burada,  $I_{final}^{OB}$  ve  $Q_{final}$  iyileştirilmiş  $I^{OB}$  ve  $Q$  bileşenlerini,  $\odot$  operatörü iki değişkenin bileşen bazlı çarpımını ve  $\beta_C$  renklilik kontrol parametresini temsil etmektedir. Yüksek  $\beta_C$  değerleri renkliliği azaltırken, düşük  $\beta_C$  değerleri yüksek renkliliğe sahip sonuçlar üretmektedir. Görüntüde renk kayıplarının önüne geçebilmek için  $\beta_C$  parametresi  $[0,5 \ 1]$  aralığında seçilmelidir. Sonuç görüntüsü  $Y_{final}$ ,  $I_{final}^{OB}$  ve  $Q_{final}$  bileşenlerine ters YIQ dönüşümü uygulanarak elde edilmiştir. Tüm iyileştirme prosedürü Tablo 2.4'te verilmiştir.

**Tablo 2.4.** Önerilen ACGC yöntemi ile iyileştirme için sözde kod.

---

**Girdi:**

$I$  : düşük aydınlık giriş görüntüsü,  $\sigma_r$  : aralık çekirdeği,  $\sigma_s$  : uzamsal çekirdek,

$\beta_C$  : renklilik faktörü  $\gamma$  : gama düzeltme katsayısı

**İşlem:**

*Adım 1:* Giriş görüntüsüne Denklem 2.26 ile gama düzeltme uygula

*Adım 2:* Y bileşenine Denklem 2.28 ve Denklem 2.29 ile ayrıştıma uygula

*Adım 3:* Düşük frekans bileşenine Denklem 2.31 ile yerel gama düzeltme uygula

*Adım 4:* İyileştirilmiş Y bileşenini elde etmek için Denklem 2.34 ile parlaklık ağırlıklandırması uygula

*Adım 5:*  $I^{OB}$  ve  $Q$  bileşenlerine Denklem 2.36 ile yerel gama düzeltmesi uygula

**Çıktı:**

İyileştirilmiş görüntü

---

### 3. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, tez kapsamında önerilen yöntemlerin geçerliliğini test etmek, üstün ve zayıf yönlerini objektif bir biçimde değerlendirmek amacıyla literatürde sıklıkla kullanılan veri kümeleriyle deneysel çalışmalar yapılmıştır. Ayrıca, önerilen yöntemlerin literatürde kendini ispatlamış yöntemler ile karşılaştırmalı analizi yapılmıştır.

Bölümün akışı şu şekildedir; ilk olarak karşılaştırmada kullanılan yöntemler ve veri kümeleri anlatılmış, ardından önerilen yöntemlerin nicel sonuçlarının analizinde kullanılan performans ölçütleri anlatılmıştır. Daha sonra, önerilen yöntemlere ait uygulama detayları, görsel sonuçlar, nicel sonuçlar ve bulgular farklı alt başlıklar altında değerlendirilmiştir. Son olarak, tez kapsamında önerilen yöntemlerin kendi içinde değerlendirilmesi paylaşılmıştır.

#### 3.1. Karşılaştırmada Kullanılan Yöntemler

Tez kapsamında önerilen yöntemlerin performansını objektif bir şekilde test etmek için hem geleneksel hem de derin öğrenme tabanlı yöntemlerle karşılaştırmalar yapılmıştır. Geleneksel yöntemler; SRIE (Fu et al., 2016), LIME (Guo et al., 2017), Robust Retinex (Li et al., 2018), Jeon and Eom (2022), Wang et al. (2023) ve GCP-MCS (Jeon et al., 2024) olarak belirlenmiştir. Derin öğrenme tabanlı yöntemlerden ise literatürde nicel karşılaştırmalarda sıklıkla kullanılan; DeepUPE (Wang et al., 2019), EnlightenGAN (Jiang et al., 2021), Zero-DCE (Li et al., 2022) ve SCI (Ma et al., 2022) yöntemleri seçilmiştir.

#### 3.2. Kullanılan Veri Kümeleri

Tez kapsamında önerilen yöntemlerin görsel ve nicel yeteneklerini açık bir şekilde ortaya koyabilmek için çeşitli düşük aydınlıklı görüntü özelliklerini içeren veri kümelerine uygulanmıştır. Kullanılan veri kümeleri detaylı olarak aşağıda açıklanmıştır.

- *DICM*: Çeşitli aşırı pozlamalı ve düşük pozlamalı günlük görüntüleri içerir ve 64 görüntüden oluşur (Lee et al., 2013).
- *LIME*: Ekstra karanlık görüntüleri içerir ve 10 görüntüden oluşur (Guo et al., 2017).

- *MEF*: 17 görüntüye ait çoklu pozlama görüntü dizilerinden oluşur (Ma et al., 2015).
- *NPE*: Gece ve düşük pozlamalı gündüz görüntülerini içeren 84 görüntüden oluşur (Wang et al., 2013).
- *VV*: Düşük pozlamalı günlük görüntüleri içeren 24 görüntüden oluşur (Vonikakis et al., 2018).
- *All Test Set*: Yukarıdaki bahsedilen veri kümelerine ek olarak “*Fusion*” ve “*Low*” adında iki veri kümesini daha içerir ve toplamda 360 görüntüden oluşur (Jiang et al., 2021).
- *VE-LOL-H*: LOL veri kümesinin gelişmiş versiyonudur. 10.940 eşleştirilmemiş gerçek görüntü içerir. Bu görüntüler, eğitim ve doğrulama için 6.940, test için 4.000 olacak şekilde ayrılmıştır. Bu tez kapsamında, eğitim ve doğrulama için kullanılan 6.940 görüntü kullanılmıştır (Liu et al., 2021).
- *Berkeley Deep Driving (BDD-100k)*: Araç içi kamerasından yakalanan gerçek dünya görüntülerini içerir ve 100.000 görüntüden oluşur (Yu et al., 2020).
- *Part2 Subset*: SICE veri kümesinin alt kümesidir ve 229 eşleştirilmiş görüntüden oluşur. Bu görüntüler, farklı pozlama seviyelerinden oluşan pozlama dizilerine sahiptir (Cai et al., 2018).
- *VE-LOL-L*: 1.000 sentetik eşleştirilmiş görüntü (VE-LOLSyn) ve 500 gerçek eşleştirilmiş görüntü (VE-LOLCap) olmak üzere toplamda 1.500 görüntüden oluşur (Liu et al., 2021).
- *RELLISUR*: Her biri beş farklı pozlamaya sahip 85 farklı görüntü olmak üzere toplamda 425 eşleştirilmiş görüntüden oluşur (Aakerberg et al., 2021).

### 3.3. Performans Ölçütleri

Tez kapsamında önerilen yöntemlerin nicel analizinin yapılabilmesi için referanslı ve referanssız performans ölçütleri kullanılmıştır. Daha nesnel bir analiz elde edebilmek amacıyla, düşük aydınlıklı görüntülerin çeşitli özelliklerine odaklanan performans ölçütleri kullanılmıştır. Kullanılan performans ölçütleri detaylı olarak aşağıda açıklanmıştır.

- *Tepe Sinyal-Gürültü Oranı*: Tepe Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio, PSNR), görüntü kalitesi hakkında bilgi veren bir referanslı metriktir. Daha yüksek PSNR değeri, test görüntüsü ile kesin referans görüntüsü arasındaki benzerliğin daha fazla olduğu anlamına gelir. PSNR değeri Denklem 3.1'deki gibi hesaplanır.

$$PSNR(f, g) = 10 \log_{10}(255^2 / MSE(f, g)) \quad (3.1)$$

$$MSE(f, g) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N (f_{mn} - g_{mn})^2 \quad (3.2)$$

Burada,  $f$  test görüntüsünü,  $g$  kesin referans görüntüsünü,  $MSE$  ortalama karesel hatayı,  $M$  ve  $N$  görüntünün genişliğini ve yüksekliğini,  $m$  ve  $n$  piksel lokasyonunu temsil etmektedir.

- *Yapısal Benzerlik İndeksi Ölçümü*: Yapısal Benzerlik İndeksi Ölçümü (Structural Similarity Index Measure, SSIM), iki görüntü arasındaki benzerlik hakkında bilgi veren referanslı bir metriktir (Wang et al., 2004). Daha yüksek SSIM değeri, iki görüntü arasındaki benzerliğin daha fazla olduğunu gösterir. SSIM değeri Denklem 3.3'teki gibi hesaplanır.

$$SSIM(f, g) = \frac{(2\mu_f \mu_g + c_1)(2\sigma_{fg} + c_2)}{(\mu_f^2 + \mu_g^2 + c_1)(\sigma_f^2 + \sigma_g^2 + c_2)} \quad (3.3)$$

Burada,  $\mu_f$  test görüntüsünün ortalamasını,  $\mu_g$  kesin referans görüntüsünün ortalamasını,  $\sigma_f^2$  test görüntüsünün varyansını,  $\sigma_g^2$  kesin referans görüntüsünün varyansını,  $\sigma_{fg}$  iki görüntü arasındaki kovaryansı,  $c_1$  ve  $c_2$  küçük sabitleri temsil etmektedir.

- *Düşük Aydınlık Görüntü İyileştirme Kalitesi Değerlendirmesi*: Düşük Aydınlık Görüntü İyileştirme Kalitesi Değerlendirmesi (Low-Light Image Enhancement Quality Assessment, LIEQA), iyileştirme performansı hakkında bilgi veren referanslı bir metriktir (Zhai et al., 2021). Daha yüksek LIEQA değeri, düşük aydınlıklı görüntü iyileştirme performansının daha iyi olduğunu gösterir. LIEQA değeri, parlaklık iyileştirmesi, renk sunumu, gürültü değerlendirmesi ve yapı koruması hakkında oluşturulan dört adet değer in çarpımından elde edilir.
- *Doğal Görüntü Kalitesi Değerlendiricisi*: Doğal Görüntü Kalitesi Değerlendiricisi (Natural Image Quality Evaluator, NIQE), görüntünün görsel

kalitesi hakkında bilgi veren referanssız bir metriktir (Mittal et al., 2012). Daha düşük NIQE değeri, iyileştirilen görüntünün daha yüksek bir görsel kaliteye sahip olduğunu gösterir. NIQE, kaliteye duyarlı Doğal Sahne İstatistiklerini kullanarak görsel kaliteyi değerlendirir. Çok değişkenli Gauss modeli  $(v_p, \Sigma_p)$  ile bozulmamış görüntü özelliklerini modeller ve test görüntüsünün özellik modeline  $(v_d, \Sigma_d)$  olan mesafe olarak ölçer. NIQE değeri Denklem 3.4'teki gibi hesaplanır.

$$NIQE = \sqrt{\left( (v_p - v_d)^T \left( \frac{\Sigma_p + \Sigma_d}{2} \right)^{-1} (v_p - v_d) \right)} \quad (3.4)$$

Burada,  $v_p$  doğal görüntü modelinin ortalama vektörünü,  $v_d$  test görüntüsünün ortalama vektörünü,  $\Sigma_p$  doğal görüntü modelinin kovaryans matrisini ve  $\Sigma_d$  test görüntüsünün kovaryans matrisini temsil etmektedir.

- *Algıya Dayalı Görüntü Kalite Değerlendiricisi:* Algıya Dayalı Görüntü Kalitesi Değerlendiricisi (Perception-Based Image Quality Evaluator, PIQE), insan algısına dayalı görsel kalite hakkında bilgi veren referanssız bir metriktir (Venkatanath et al., 2015). Daha düşük PIQE değeri, iyileştirilen görüntünün daha düşük algısal bozukluğa sahip olduğunu gösterir. PIQE değeri Denklem 3.5'teki gibi hesaplanır.

$$PIQE = \frac{\left( \sum_{k_{SA}=1}^{N_{SA}} D_{sk} \right) + C_1^{SA}}{N_{SA} + C_1^{SA}} \quad (3.5)$$

Burada,  $N_{SA}$  uzamsal aktif blokların sayısını,  $C_1^{SA}$  sayısal kararsızlığı önlemek için dahil edilen pozitif sabiti ve  $D_{sk}$  belirli bir blok için bozulma skorunu temsil etmektedir.


- *Referanssız Düşük Işık Görüntü İyileştirme Değerlendirmesi:* Referanssız Düşük Işık Görüntü İyileştirme Değerlendirmesi (No-Reference Low-Light Image Enhancement Evaluation, NLIEE), aydınlatma iyileştirmesini, renk karşılaştırmasını, gürültü ölçümünü ve yapı benzerliğini dikkate alır (Zhang et al., 2021). Daha düşük NLIEE değeri, düşük aydınlık iyileştirme performansının daha iyi olduğunu gösterir. Kalite skorunu oluşturmak amacıyla aydınlatma iyileştirmesi, renk karşılaştırması, gürültü ölçümü ve yapı değerlendirmesini göz önünde bulunduran 18 adet öznetelik çıkarılır. Elde edilen öznetelik vektörü, destek vektör regresyon modeli ile birlikte tek kalite skoruna dönüştürülür.

### 3.4. Önerilen SSIF Yöntemi Sonuçları

Bu alt başlıkta, tez kapsamında önerilen “Keskinleştirme-Yumuşatma Görüntü Filtresine Dayalı Düşük Aydınlıklı Görüntü İyileştirme” adlı yöntemle ait uygulama detayları, görsel sonuçlar, nicel sonuçlar ve bulgular verilmiştir.

#### 3.4.1. Uygulama Detayları

Önerilen SSIF yönteminde kullanılan her bir parametrenin etkisini göstermek amacıyla çeşitli uygulama çalışmaları yapılmıştır. SSIF için optimum parametrelerini belirlemek amacıyla bütün filtre parametrelerinin PSNR değeri üzerindeki etkileri incelenmiştir. Bu amaçla karışıklık, pozlama ve görünürlük bakımından farklı özelliklere sahip 27 görüntü üzerinde uygulama çalışmaları yürütülerek ortalama PSNR değerleri hesaplanmıştır. Bu çalışmalara göre,  $\kappa$  değerinin iyileştirme sonuçları üzerinde anlamlı bir etkisinin olduğu gözlemlenmiştir. Farklı  $\kappa$  değerlerinin PSNR üzerindeki etkisini gösteren grafik Şekil 3.1’de verilmiştir.




Şekil 3.1. Farklı kappa değerleri ile elde edilen PSNR değerleri.

Diğer parametrelerin ortalama PSNR değeri üzerinde ihmal edilebilir bir etkisi vardır. Yapılan çalışma sonucunda en yüksek PSNR değerlerine sahip tüm parametreler optimum değerler olarak belirlenmiştir. Önerilen SSIF yönteminin parametreleri  $\kappa = 2$ ,  $r = 19$ ,  $\varepsilon = 0,001$  ve  $s = 0,1$  olarak ayarlanmıştır.

#### 3.4.2. Görsel Sonuçlar


Önerilen SSIF yönteminin görsel analizinin nesnel bir şekilde yapılabilmesi için literatürde sıklıkla kullanılan yöntemlerle kıyaslama yapılmıştır. Ayrıca sonuçları daha net görebilmek için görüntülerin bazı kısımları yakınlaştırılarak görüntülerin altında verilmiştir. Şekil 3.2’de “Eyfel Kulesi-1” görüntüsü için iyileştirme sonuçları verilmiştir.



**Şekil 3.2.** Eyfel Kulesi-1 görüntüsü için iyileştirme sonuçları.

Şekil 3.2’de, SRIE gökyüzünün bazı kısımlarında az miktarda gürültüye sebep olmaktadır. Buna ek olarak, aydınlatma iyileştirmesi yetersizdir. LIME, iyileştirme sonucunda gürültüyü yükseltmiştir. Ayrıca, yeşil kutuda görüldüğü gibi renk bozulmaları meydana gelmektedir. Robust Retinex, kırmızı kutuda görüldüğü gibi görüntüde detay kayıplarına neden olmuştur. DeepUPE, iyileştirme sonucunda yeterli aydınlatma iyileştirmesi sağlayamamıştır. EnlightenGAN her iki yakınlaştırılmış bölgede görüldüğü gibi parlamalara yol açmıştır. Zero-DCE, yeşil kutuda görüldüğü gibi gökyüzü bölgesinde yoğun gürültüye sahiptir. Kırmızı kutuda ise bina üzerinde renk bozulmaları olduğu görülmektedir. Önerilen SSIF yöntemi, görünürlük ve doğallık açısından etkili bir iyileştirme sonucu üretmiştir.


Şekil 3.3’te “Sokak-1” görüntüsüne ait iyileştirme sonuçları verilmiştir.



**Şekil 3.3.** Sokak-1 görüntüsü için iyileştirme sonuçları.

Şekil 3.3’te, SRIE her iki yakınlştırılmış bölgede görüldüğü gibi önemli iyileştirme sağlamıştır. Kırmızı kutuda görüldüğü gibi ağaç dalları SRIE yönteminde görünürdür ancak gökyüzü bölgesinde gürültü ve bozulmalara neden olmuştur. Kırmızı kutuda görüldüğü gibi LIME yöntemi ciddi gürültü içermektedir. Robust Retinex, yeterli aydınlatma iyileştirmesi sağlayamamıştır ve yumuşatma sebebiyle bilgi kayıplarına neden olmuştur. DeepUPE, bazı bölgelerde aydınlatmayı aşırı derecede artırırsa da ağaç dalları hala görünür değildir. EnlightenGAN, gökyüzü bölgesinde yoğun gürültülü ve genel olarak aşırı parlak bir sonuç üretmiştir. Zero-DCE, kırmızı kutudaki duvar bölgesini önceki yöntemlerden daha iyi iyileştirmiş olmasına rağmen aşırı gürültü ve doğal olmayan renklerden muzdariptir. Önerilen SSIF yönteminde, ağaç dalları görünür durumdadır. Ayrıca, gürültü, renk bozulması ve bölgesel parlamalar içermemektedir.


Düşük aydınlıklı iyileştirme yöntemlerinin farklı aydınlatma koşullarına göre uyarlanabilir olması gerekir. Şekil 3.4’te “Gündüz-1” görüntüsüne ait iyileştirme sonuçları verilmiştir.



**Şekil 3.4.** Gündüz-1 görüntüsü için iyileştirme sonuçları.

Şekil 3.4’te, yeşil kutuda görüldüğü gibi önerilen SSIF yöntemi ahşap ve çiçek detaylarında en iyi renk korumasını sağlamıştır. Ayrıca, duvar bölgesinde görüldüğü gibi diğer yöntemlerden daha iyi detay iyileştirmesi elde edilmiştir.


Düşük aydınlıklı görüntü iyileştirme yöntemlerinin yeterli aydınlatmaya sahip bölgeleri bozmadan yetersiz aydınlatmaya sahip bölgeleri iyileştirmesi gerekir. Bu özelliğe sahip olan “Kişi-1” görüntüsü için iyileştirme sonuçları Şekil 3.5’te verilmiştir.



**Şekil 3.5.** Kişi-1 görüntüsü için iyileştirme sonuçları.

Şekil 3.5’te, Zero-DCE arka plan aydınlatmasını iyileştirmede en iyi sonucu elde etmiştir. Ancak önerilen SSIF yöntemi yüz bölgesinde en az renk bozulması ve detay kaybıyla en iyi sonucu üretmektedir.

Önerilen SSIF yönteminin pratikteki avantajlarını göstermek için gerçek dünya görüntülerinden oluşan BDD-100k veri kümesinden düşük aydınlıklı görüntüler rastgele seçilmiştir. Seçilen görüntüler zayıf görünürlük ve düşük kontrastlıktan muzdariptir. Şekil 3.6’da “Yol-1” görüntüsü için iyileştirme sonuçları verilmiştir.



**Şekil 3.6.** Yol-1 görüntüsü için iyileştirme sonuçları.

Şekil 3.6’da, SRIE en düşük gürültüye sahip olmasına rağmen diğer yöntemlerden daha karanlık sonuç üretmiştir. LIME, görüntüdeki ışık kaynağı olan bölgelerde yoğun gürültülü sonuçlar üretmiştir. Robust Retinex, otobüsün önündeki asfaltta ve otobüsün içinde bazı detay kayıplarına neden olmuştur. DeepUPE, yeterli iyileştirme sağlayamamıştır. EnlightenGAN, görüntünün sağ tarafında görülen ve renk bozulmasına

sebepe olan yüksek gürültüden muzdariptir. Zero-DCE, görünürlük açısından iyi sonuçlar üretir ancak yeterince doğal sonuçlar üretememiştir. Önerilen SSIF yöntemi, tartışılan tüm görsel özellikler açısından en dengeli sonucu elde etmiştir.


Gerçek dünya görüntüleri üzerinde yapılan deneylere ait bir diğer sonuç ise Şekil 3.7’de “Otoyol” görüntüsü ile verilmiştir.



**Şekil 3.7.** Otoyol görüntüsü için iyileştirme sonuçları.

Şekil 3.7’de, SRIE yol bölgesi için yüksek görünürlüğe sahip sonuçlar üretmiştir ancak gökyüzü bölgesinde bozulmalara sebep olmuştur. LIME ve Robust Retinex, araçların arka lambalarının etrafında parlamalara sebep olarak bazı detayların kaybolmasına neden olmuştur. DeepUPE, yeterli aydınlatma iyileştirmesi sağlayamamıştır. EnlightenGAN, yoğun gürültü sebebiyle doğal olmayan renkler ve parlamalar oluşturmuştur. Zero-DCE, gökyüzü bölgesinde istenmeyen renk değişimlerine neden olan aşırı gürültüye sahiptir. Önerilen SSIF yöntemi daha iyi görsel kalite ve karşılıklı iyileştirmesi sağlamıştır.

Şekil 3.8’de, araç içinde yakalanan gece sürüşüne ait “Yaya geçidi” görüntüsü için iyileştirme sonuçları verilmiştir.



**Şekil 3.8.** Yaya geçidi görüntüsü için iyileştirme sonuçları.

Şekil 3.8’de, SRIE etkili bir karşıtlık iyileştirmesi sağlamasına rağmen hala gürültüden muzdariptir. Ayrıca, yaya geçidi üzerinde istenmeyen gölge efektine sebep olmuştur. LIME, ışık kaynakları etrafında bozulmalara ve parlamalara neden olmuştur. Robust Retinex, doğal renklere ve düşük gürültüye sahip sonuçlar üretmiştir, ancak yumuşatma nedeniyle bina pencereleri gibi bazı detayların görünürlüğü azalmıştır. DeepUPE, aydınlık bölgelerde aşırı pozlama ve karanlık bölgelerde düşük pozlamadan muzdariptir. EnlightenGAN, parlaklığı artırmasına rağmen görüntünün sol üst bölgesindeki gibi doğal olmayan renklere sebep olmuştur. Zero-DCE, yüksek gürültü ve yapay renk oluşumunun önüne geçememiştir. Önerilen SSIF yöntemi, düşük gürültülü, doğal renklere sahip ve belirgin ayrıntılara sahip bir sonuç üretmiştir.

### 3.4.3. Nicel Sonuçlar

Tez kapsamında önerilen SSIF yönteminin nicel analizinin nesnel bir şekilde yapılabilmesi için düşük aydınlıklı görüntü iyileştirme konusunda literatürde sıklıkla kullanılan performans ölçütleri kullanılmıştır. Düşük aydınlıklı görüntü iyileştirme performansını kapsamlı bir şekilde değerlendirmek için referanslı metrikler olan PSNR, SSIM ve LIEQA ile birlikte referanssız metrikler olan NIQE ve NLIEE kullanılmıştır. Referanslı metriklere ait nicel sonuçlar Tablo 3.1’de verilmiştir. Tablo 3.1’de, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.1.** Karşılaştırma veri kümeleri için referanslı metrik sonuçları.

| Yöntem          | Metrik | Veri Kümesi   |               |
|-----------------|--------|---------------|---------------|
|                 |        | Part2 Subset  | VE-LOL-L      |
| SRIE            | PSNR   | 14,416        | 13,601        |
|                 | SSIM   | 0,549         | 0,403         |
|                 | LIEQA  | 0,211         | <u>0,104</u>  |
| LIME            | PSNR   | 16,178        | 13,479        |
|                 | SSIM   | 0,573         | 0,394         |
|                 | LIEQA  | <u>0,317</u>  | 0,078         |
| Robust Retinex  | PSNR   | 15,197        | 14,091        |
|                 | SSIM   | 0,544         | 0,394         |
|                 | LIEQA  | 0,183         | 0,081         |
| DeepUPE         | PSNR   | 14,426        | 13,530        |
|                 | SSIM   | <u>0,691</u>  | <u>0,409</u>  |
|                 | LIEQA  | 0,151         | 0,099         |
| EnlightenGAN    | PSNR   | 16,213        | <b>14,858</b> |
|                 | SSIM   | 0,591         | <b>0,449</b>  |
|                 | LIEQA  | 0,198         | 0,101         |
| Zero-DCE        | PSNR   | <u>16,572</u> | <u>14,271</u> |
|                 | SSIM   | 0,594         | 0,375         |
|                 | LIEQA  | 0,131         | <b>0,108</b>  |
| Önerilen Yöntem | PSNR   | <b>16,713</b> | 13,140        |
|                 | SSIM   | <b>0,735</b>  | 0,388         |
|                 | LIEQA  | <b>0,364</b>  | 0,076         |

Part2 Subset veri kümesinde, önerilen SSIF yöntemi tüm metriklerde en iyi sonuçları elde etmiştir. Zero-DCE, ikinci en iyi PSNR değerine ulaşmıştır. DeepUPE, SSIM metriği açısından ikinci en iyi performansa sahiptir. LIME, iyileştirme performansı hakkında bilgi veren LIEQA metriğinde ikinci en iyi sonucu elde etmiştir. VE-LOL-L veri kümesinde, EnlightenGAN en iyi PSNR ve SSIM değerlerini elde etmiştir. Zero-DCE en iyi LIEQA sonucuna ulaşmıştır. Zero-DCE ikinci en iyi PSNR değerine, DeepUPE ikinci en iyi SSIM değerine ve SRIE ikinci en iyi LIEQA değerine ulaşmıştır.

Referanssız metriklere ait nicel sonuçlar Tablo 3.2’de verilmiştir. Tablo 3.2’de, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.2.** Karşılaştırma veri kümeleri için referanssız metrik sonuçları.

| Yöntem | Metrik | Veri Kümesi |               |        |        |        |              |          |
|--------|--------|-------------|---------------|--------|--------|--------|--------------|----------|
|        |        | DICM        | LIME          | MEF    | VV     | NPE    | All Test Set | VE-LOL-H |
| SRIE   | NIQE   | 3,899       | <u>3,788</u>  | 3,475  | 2,850  | 3,986  | 3,650        | 3,538    |
|        | NLIEE  | 49,686      | <u>49,541</u> | 44,039 | 48,092 | 54,723 | 50,791       | 38,356   |
| LIME   | NIQE   | 3,846       | 4,155         | 3,720  | 2,489  | 4,268  | 3,629        | 3,954    |
|        | NLIEE  | 48,730      | 50,883        | 44,058 | 49,863 | 56,210 | 51,618       | 36,984   |

**Tablo 3.2.** Karşılaştırma veri kümeleri için referanssız metrik sonuçları (devamı).

|           |       |               |               |               |               |               |               |               |
|-----------|-------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
| Robust    | NIQE  | <b>3,238</b>  | 4,108         | 4,204         | 2,623         | 4,047         | 3,670         | 4,014         |
| Retinex   | NLIEE | 51,895        | 52,957        | 46,102        | 48,346        | 58,177        | 53,381        | 39,747        |
| DeepUPE   | NIQE  | <b>3,238</b>  | 3,789         | 3,860         | 2,237         | 3,589         | 3,491         | 3,327         |
|           | NLIEE | 42,166        | <b>48,309</b> | 41,806        | 42,367        | 52,285        | 47,249        | 36,949        |
| Enlighten | NIQE  | 3,570         | <b>3,719</b>  | 3,232         | 2,581         | 4,113         | 3,385         | 2,592         |
| GAN       | NLIEE | 52,414        | 53,765        | 46,094        | 37,229        | <b>48,027</b> | 48,208        | 47,288        |
| Zero-DCE  | NIQE  | 3,309         | 4,045         | <b>3,123</b>  | 2,794         | 3,734         | 3,506         | <b>2,581</b>  |
|           | NLIEE | <b>40,213</b> | 50,636        | <b>39,907</b> | <u>36,727</u> | 52,149        | <u>45,955</u> | <b>29,912</b> |
| Önerilen  | NIQE  | <u>3,282</u>  | 3,870         | 3,503         | <b>1,965</b>  | <b>3,577</b>  | <b>3,358</b>  | 3,625         |
| Yöntem    | NLIEE | <u>41,712</u> | 50,800        | <u>40,312</u> | <b>32,734</b> | <u>51,949</u> | <b>43,707</b> | <u>35,063</u> |

Çoklu pozlama görüntülerinden oluşan DICM veri kümesinde Robust Retinex ve DeepUPE en iyi NIQE değerini elde ederken Zero-DCE en iyi NLIEE değerini elde etmiştir. Önerilen SSIF yöntemi, bu yöntemlerin ardından ikinci en iyi NIQE ve NLIEE değerini elde etmiştir. Ekstra karanlık görüntüler içeren LIME veri kümesinde, EnlightenGAN en iyi NIQE değerine ulaşırken DeepUPE en iyi NLIEE değerine ulaşmıştır. MEF veri kümesinde, Zero-DCE en iyi değerleri elde ederken EnlightenGAN ikinci en iyi NIQE değerini ve önerilen SSIF yöntemi en iyi ikinci NLIEE değerini elde etmiştir. Önerilen SSIF yöntemi, düşük pozlamalı görüntülerden oluşan VV veri kümesinde en iyi sonuçlara ulaşmıştır. Ayrıca, DeepUPE ikinci en iyi NIQE sonucuna ve Zero-DCE ikinci en iyi NLIEE sonucuna ulaşmıştır. Daha önce belirtilen veri kümelerini içeren All Test Set veri kümesinde ise önerilen SSIF yöntemi iki performans ölçütünde de en iyi performansı göstermiştir. EnlightenGAN ikinci en iyi NIQE performansını gösterirken Zero-DCE ikinci en iyi NLIEE performansını göstermiştir. VE-LOL-H veri kümesinde , Zero-DCE iki metrikte de en iyi değerleri elde etmiştir. EnlightenGAN, ikinci en iyi NIQE değerini ve önerilen SSIF yöntemi ikinci en iyi NLIEE değerini elde etmiştir.

Performans ölçütlerinin yanı sıra eğitilebilir parametre sayısı ve ortalama çalışma süresi diğer yöntemlerle kıyaslanmıştır. Bir öğrenme modelindeki eğitilebilir parametre sayısı, modelin karmaşıklığının ve kapasitesinin bir göstergesidir. Çıkarım süresi ise bir modelin hesaplama verimliliğinin ölçüsüdür. Ortalama çalışma süresini hesaplayabilmek için  $625 \times 625 \times 3$  boyutlarında 20 adet görüntü seçilmiştir. Seçilen 20 görüntü üzerinde gerçekleşen toplam işlem süresi görüntü sayısına bölünerek ortalama süre elde edilmiştir. Yapılan tüm işlemler 2,3 GHz hızında 11. Nesil Intel Core i7-11800H MİB, 16 GB RAM ile Nvidia RTX 3060 6 GB GİB'e sahip bir kişisel bilgisayarda gerçekleştirilmiştir.

Ortalama çalışma süresi ve eğitilebilir parametrelere ait sonuçlar Tablo 3.3'te sunulmuştur.

**Tablo 3.3.** Karşılaştırmada kullanılan yöntemlerin ortalama çalışma zamanı (sn) ve eğitilebilir parametrelerinin karşılaştırılması.

| Yöntem          | Ortalama Çalışma Süresi | Eğitilebilir Parametre | Platform        |
|-----------------|-------------------------|------------------------|-----------------|
| SRIE            | 5,809                   | -                      | MATLAB(MİB)     |
| LIME            | 0,491                   | -                      | MATLAB(MİB)     |
| Robust Retinex  | 13,286                  | -                      | MATLAB(MİB)     |
| DeepUPE         | 0,965                   | 998.816                | Tensorflow(GİB) |
| EnlightenGAN    | 0,148                   | 8.636.675              | Pytorch(GİB)    |
| Zero-DCE        | 0,047                   | 79.416                 | Pytorch(GİB)    |
| Önerilen Yöntem | 0,080                   | -                      | MATLAB(MİB)     |

Tablo 3.3'te görüldüğü gibi önerilen yöntem, iyileştirme işlemlerini MİB üzerinde gerçekleştirmesine rağmen DeepUPE ve EnlightenGAN gibi GİB üzerinde işlem yapan yöntemlerden daha iyi performans göstermiştir. Önerilen SSIF yöntemi, Zero-DCE yönteminin ardından 0,033 sn fark ile ikinci en iyi ortalama çalışma süresine sahiptir.

#### 3.4.4. Bulgular

Tez kapsamında önerilen SSIF yöntemi üzerinde gerçekleştirilen deneysel çalışmalar sonucunda önerilen düşük aydınlık iyileştirme yönteminin ayrıntı koruma, görsel kalite ve renk doğallığı açısından literatürdeki yöntemlere kıyasla üstün performans gösterdiği belirlenmiştir. Görsel karşılaştırmalarda, güncel yöntemlerin gürültü, aşırı aydınlatma, renk bozulmaları ve ayrıntı kaybı gibi sorunları gideremediği gözlenmiştir. Bu gibi sorunlara karşılık, önerilen SSIF yöntemi düşük gürültü, görünürlük, doğal renkler ve ayrıntı koruma açısından daha dengeli sonuçlar üretmiştir. Referanslı metrikler kullanılarak yapılan analizlerde önerilen SSIF yöntemi aydınlatma iyileştirmesi ve yapısal bilginin korunması açısından üstün performans göstermiştir. Referanssız metrikler kullanılarak elde edilen sonuçlara göre önerilen SSIF yöntemi, doğal sahne istatistiklerine uygunluk ve görsel kaliteyi iyileştirmesi açısından rakiplerinden daha başarılıdır. Sonuç olarak, önerilen SSIF yöntemi hem görsel değerlendirmede hem de nicel değerlendirmede tatmin edici sonuçlar üreterek düşük aydınlıklı görüntü iyileştirme alanında güçlü bir alternatif olduğunu kanıtlamıştır.


### 3.5. Önerilen MT Yöntemi Sonuçları

Bu alt başlıkta, tez kapsamında önerilen “Metropolis Teoremine Dayalı Piksel Bazında Düşük Aydınlıklı Görüntü İyileştirme” adlı yöntemle ait uygulama detayları, görsel sonuçlar, nicel sonuçlar ve bulgular verilmiştir.

#### 3.5.1. Uygulama Detayları

İyileştirilmiş görüntülerde daha kaliteli sonuçlar elde etmek için çeşitli parametreler belirlenmelidir. Yapılan deneyler sonucunda, giriş görüntüsüne yapılan ön düzeltmedeki gama katsayısı  $\gamma = 0,5$  olarak ayarlanmıştır. MT’nin çok ölçekli ayrıştırılması için  $T = 300$  ve  $\xi = 2$  olacak şekilde iki ayrıştırma seviyesi uygulanmıştır.

Önerilen MT yönteminde, genel gama düzeltmesi (gamma correction, GC), HSV dönüşümü, MT uygulaması ve yerel gama düzeltmesi (local gamma correction, LGC) olmak üzere dört bileşenin iyileştirme sonucuna katkısı incelenmiştir. Her bir bileşen sırayla kaldırılarak iyileştirme sonuçları gözlemlenmiştir. Şekil 3.9’da bileşenlerin etkisini gösteren iyileştirme sonuçları sunulmuştur.



**Şekil 3.9.** Her bir bileşenin sırayla çıkarılmasıyla elde edilen görsellerin karşılaştırılması. (a) Giriş görüntüsü, (b) GC uygulanmadan elde edilen sonuç görüntüsü, (c) HSV uygulanmadan elde edilen sonuç görüntüsü, (d) MT uygulanmadan elde edilen sonuç görüntüsü, (e) LGC uygulanmadan elde edilen sonuç görüntüsü, (f) önerilen yöntem ile elde edilen sonuç görüntüsü.

Şekil 3.9’da görüldüğü gibi gama düzeltmesi olmadan elde edilen sonuç yetersiz aydınlatma iyileştirmesi sebebiyle ayrıntıları ortaya çıkaramamıştır. HSV dönüşümü olmadan elde edilen sonuç ise renk bozulmalarından muzdariptir. MT uygulamasının olmaması ayrıntıların korunamamasına yol açan aşırı pozlamalı sonuçlar üretmiştir. Bu sebeple, MT iyi bir iyileştirme performansı elde edilebilmesi için önerilen yöntemde temel parçalardan biridir. Son olarak, yerel gama düzeltmesi olmadan elde edilen


sonular bazı blgelerde biraz daha karanlık alanların oluřmasına neden olmuřtur. Grsel sonular, nerilen ervedeki her bir bileřenin yksek kaliteye sahip iyileřtirme sonucu elde etmek iin nemli bir rol oynadıėını gstermektedir. Buna ek olarak, nerilen ervedeki her bir bileřenin etkisini nicel olarak gstermek iin RELLISUR zerinde de deneyler yapılmıřtır. Bu deneylere ait sonular Tablo 3.4’te sunulmuřtur.

**Tablo 3.4.** Her bir bileřenin sırayla ıkarılmasıyla elde edilen nicel sonular.

|      | GC hari | HSV hari | MT hari | LGC hari | nerilen Yntem |
|------|----------|-----------|----------|-----------|-----------------|
| PSNR | 14,001   | 18,204    | 16,839   | 17,529    | <b>18,454</b>   |
| SSIM | 0,388    | 0,552     | 0,538    | 0,547     | <b>0,561</b>    |

Tablo 3.4’te, en iyi PSNR ve SSIM deėerleri nerilen yntem ile elde edilmiřtir. Nicel sonular, her bir bileřenin iyileřtirme sonucunda nemli bir rol oynadıėını doėrulamıřtır.

Ayrıřtırma seviyesinin, MT ayrıřtırma prosedrnn performansı zerindeki etkilerini gzlemlemek iin bazı deneysel alıřmalar yrtlmřtir. Bu alıřmalara iliřkin sonular řekil 3.10’da sunulmuřtur.




**řekil 3.10.** Farklı MT ayrıřtırma seviyelerinin etkisine iliřkin deneysel alıřmalar.

Şekil 3.10’da, birinci seviye ayrıştırmanın en düşük PSNR değerini elde ettiği ve daha koyu sonuç ürettiği söylenebilir. İki seviyeli ayrıştırma, tek seviye ayrıştırmaya kıyasla 2,02 dB’lik bir PSNR iyileştirmesi sağlamıştır. Ayrıca, ikiden fazla ayrıştırma seviyesine sahip sonuçlarda görsel kalite açısından önemli bir iyileştirme olmamıştır. Ayrıştırma prosedürünün zaman verimliliği ve iyileştirme performansı dikkate alınarak MT ayrıştırma seviyesi 2 olarak belirlenmiştir.

### 3.5.2. Görsel Sonuçlar

Önerilen MT yönteminin görsel analizinin nesnel bir şekilde yapılabilmesi için literatürde sıklıkla kullanılan yöntemlerle kıyaslama yapılmıştır. Ayrıca sonuçları daha net görebilmek için görüntülerin bazı kısımları yakınlaştırılarak görüntülerin altında verilmiştir. Şekil 3.11’de “Nehir” görüntüsü için iyileştirme sonuçları verilmiştir.




**Şekil 3.11.** Nehir görüntüsü için iyileştirme sonuçları.

Şekil 3.11’de, SRİE ve DeepUPE özellikle gökyüzü bölgelerinde daha karanlık sonuçlar elde etmiştir. LİME, Zero-DCE ve Wang et al. kırmızı kutuda görüldüğü gibi gökyüzünde gürültülü sonuçlar üretmiştir. EnlightenGAN, karanlık bölgedeki binaların görünürlüğünü artırmaya rağmen gökyüzündeki doğal olmayan renk oluşumunun ve nehirdeki parlamaların önüne geçememiştir. DeepUPE, EnlightenGAN ve Wang et al. yeşil kutuda görüldüğü gibi bina pencerelerinin ayrıntılarını yeterince koruyamamıştır.

Robust Retinex parlaklığı iyi bir şekilde artırsa da gökyüzündeki bulutlarda olduğu gibi bazı bölgelerde yumuşatmaya neden olmuştur. Önerilen MT yöntemi, parlaklığı yeterli miktarda artırarak ve detayları koruyarak tatmin edici iyileştirme sonuçları elde etmiştir.


Şekil 3.12 ‘de “Sokak-2” görüntüsü için iyileştirme sonuçları sunulmuştur.



Şekil 3.12. Sokak-2 görüntüsü için iyileştirme sonuçları.

Şekil 3.12’de SRIE, LIME ve DeepUPE diğer yöntemlere kıyasla daha koyu sonuçlar üretmiştir. Robust Retinex, kırmızı kutuda görüldüğü gibi aşırı yumuşatma ile birlikte bazı detayların kaybolmasına neden olmuştur. SRIE, LIME ve Wang et al. kırmızı kutuda görüldüğü gibi gerçekçi olmayan dokular üretmiştir. EnlightenGAN, parlaklık ve detaylar açısından başarılı sonuçlar üretse de ağaçların gövde bölgesinde oluşan parlamaların önüne geçememiştir. Zero-DCE, yeşil kutuda ve beyaz arabadan görülebileceği gibi yoğun gürültü ve renk bozulmalarından muzdariptir. Önerilen MT yöntemi, renk bozulmaları, parlama etkileri ve gürültü gibi bozucu etkilerin önüne geçerek görsel olarak hoş sonuçlar üretmiştir.


Şekil 3.13’te “Arkadan Aydınlatmalı Görüntü-1” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.13.** Arkadan Aydınlatmalı Görüntü-1 görüntüsü için iyileştirme sonuçları.

Şekil 3.12’de olduğu gibi Şekil 3.13’te de önerilen MT yöntemi, ilgili kesin referans görüntüsüne kıyasla en benzer sonucu elde etmiştir. Diğer yöntemler, aşırı gürültü, renk sapması veya doğal olmayan renkler gibi istenmeyen sorunlara sahip sonuçlar üretmiştir.

Şekil 3.14’te “Gün batımı” görüntüsü için iyileştirme sonuçları sunulmuştur.




**Şekil 3.14.** Gün batımı görüntüsü için iyileştirme sonuçları.

Şekil 3.14’te, önerilen MT yönteminin yanı sıra LIME, SRIE ve Wang et al. tatmin edici sonuçlar üretmiştir. LIME, gökyüzünde doğal bir görünüm sergilese de gürültüden etkilenmiştir. Dahası, kırmızı kutuda görüldüğü gibi ağaçların tepelerinde oluşan parlamaların önüne geçememiştir. EnlightenGAN ve SRIE, çayır ve dikilitaşa bazı bozulmalara ve renk sapmalarına sebep olmuştur. Zero-DCE ve Robust Retinex

dikilitaşın etrafında parlamalar oluşturmuştur. Wang et al., çitin üzerinde görüldüğü gibi renk bozulmalarına sebep olmuştur.

Şekil 3.15'te “Gündüz-2” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.15.** Gündüz-2 görüntüsü için iyileştirme sonuçları.

Şekil 3.15'te görülebileceği gibi önerilen MT yöntemi, kesin referans görüntüsüne yakın bir sonuç üretmiştir. Zero-DCE ve Wang et al., renk sapmalarının önüne geçememiştir. DeepUPE ve EnlightenGAN, doğal olmayan dokular ve gerçekçi olmayan renk üretimini engelleyememiştir. SRIE ve LIME, gökyüzü bölgesinde daha koyu sonuçlar üreterek zayıf iyileştirme performansı sergilemiştir. Robust Retinex ise yumuşatma sebebiyle bazı detayların kaybolmasına sebep olmuştur.


Şekil 3.16'da “Kişi-2” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.16.** Kişi-2 görüntüsü için iyileştirme sonuçları.

Şekil 3.16’da, SRIE, LIME ve DeepUPE arka planın parlaklığını yeterli ölçüde artıramamıştır. LIME, Zero-DCE ve Wang et al. özellikle erkeğin saçında belirgin olarak gözüken gerçekçi olmayan dokulara sahip sonuçlar üretmiştir. Robust Retinex, bazı arka plan ayrıntılarını bulanıklaştırmış ve EnlightenGAN, erkeğin omuz bölgesinde hale efektine sahip sonuçlar üretmiştir. Önerilen MT yöntemi, karanlık alanları iyileştirmenin yanı sıra belirgin yapıları koruyarak görsel olarak iyi sonuçlar üretmiştir.

Şekil 3.17’de “Aşırı Karanlık” görüntü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.17.** Aşırı karanlık görüntü için iyileştirme sonuçları.

Şekil 3.17’de görülebileceği üzere SRIE, DeepUPE ve Wang et al. karanlık bölgelere aydınlatmada başarısız olurken LIME ve Wang et al. parlak bölgeleri aşırı iyileştirmiştir. Robust Retinex, arka plandaki detayları yumuşatarak bazı detayların kaybolmasına neden olmuştur. EnlightenGAN ve Zero-DCE, binanın etrafında hale efektlerine neden olmuştur. EnlightenGAN, Zero-DCE ve önerilen MT yöntemi parlak bölgelerde aşırı iyileştirmeye sebep olmadan tüm görüntünün parlaklığını doğru bir şekilde iyileştirmiştir.

### 3.5.3. Nicel Sonuçlar

Tez kapsamında önerilen MT yönteminin nicel analizinin nesnel bir şekilde yapılabilmesi için düşük aydınlıklı görüntü iyileştirme konusunda literatürde sıklıkla kullanılan performans ölçütleri kullanılmıştır. Düşük aydınlıklı görüntü iyileştirme performansını kapsamlı bir şekilde değerlendirmek için referanslı metrikler olan PSNR ve SSIM ile birlikte referanssız metrik olan NIQE kullanılmıştır. Referanslı metriklere ait nicel sonuçlar Tablo 3.5’te verilmiştir. Tablo 3.5’te, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.5.** İki farklı veri kümesine ait referanslı metrik sonuçları.

| Yöntem          | Metrik | Veri Kümesi   |               |
|-----------------|--------|---------------|---------------|
|                 |        | Part2 Subset  | VE-LOL-L      |
| SRIE            | PSNR   | 14,416        | 13,601        |
|                 | SSIM   | 0,549         | 0,403         |
| LIME            | PSNR   | 16,178        | 13,479        |
|                 | SSIM   | 0,573         | 0,394         |
| Robust Retinex  | PSNR   | 15,197        | 14,091        |
|                 | SSIM   | 0,544         | 0,394         |
| DeepUPE         | PSNR   | 14,426        | 13,530        |
|                 | SSIM   | <b>0,691</b>  | 0,409         |
| EnlightenGAN    | PSNR   | 16,213        | <u>14,858</u> |
|                 | SSIM   | 0,591         | <b>0,449</b>  |
| Zero-DCE        | PSNR   | <u>16,572</u> | 14,271        |
|                 | SSIM   | 0,594         | 0,375         |
| Wang et al.     | PSNR   | 16,517        | 13,006        |
|                 | SSIM   | <u>0,656</u>  | 0,381         |
| Önerilen Yöntem | PSNR   | <b>16,882</b> | <b>15,406</b> |
|                 | SSIM   | 0,617         | <u>0,422</u>  |

Tablo 3.5’te görüldüğü gibi önerilen MT yöntemi PSNR metriğinde kıyaslanan yöntemlerden üstün performans sergilemiştir. Part2 Subset veri kümesinde ikinci en iyi PSNR değerine Zero-DCE, VE-LOL-L veri kümesinde ikinci en iyi PSNR değerine EnlightenGAN ulaşmıştır. DeepUPE, Part2 Subset veri kümesinde en iyi SSIM değerini elde ederken VE-LOL-L veri kümesinde en iyi SSIM değerini EnlightenGAN yöntemi elde etmiştir. Wang et al., Part2 Subset veri kümesinde ikinci en iyi SSIM değerine ulaşırken önerilen MT yöntemi ise VE-LOL-L veri kümesinde ikinci en iyi SSIM değerine ulaşmıştır.

Referanssız metrik NIQE için nicel sonuçlar Tablo 3.6’da verilmiştir. Tablo 3.6’da, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.6.** Yedi farklı veri kümesine ait NIQE sonuçları.

| Yöntem          | Veri Kümesi  |              |              |              |              |              |              |
|-----------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                 | DICM         | LIME         | MEF          | VV           | NPE          | All Test Set | VE-LOL-H     |
| SRIE            | 3,899        | 3,788        | 3,475        | 2,850        | 3,986        | 3,650        | 3,538        |
| LIME            | 3,846        | 4,155        | 3,720        | 2,489        | 4,268        | 3,629        | 3,954        |
| Robust Retinex  | <b>3,238</b> | 4,108        | 4,204        | 2,623        | 4,047        | 3,670        | 4,014        |
| DeepUPE         | <b>3,238</b> | 3,789        | 3,860        | 2,237        | 3,589        | 3,491        | 3,327        |
| EnlightenGAN    | 3,570        | <u>3,719</u> | <u>3,232</u> | 2,581        | 4,113        | <u>3,385</u> | <u>2,592</u> |
| Zero-DCE        | <u>3,309</u> | 4,045        | <b>3,123</b> | 2,794        | 3,734        | 3,506        | <b>2,581</b> |
| Wang et al.     | 3,479        | 3,925        | 4,087        | <u>2,098</u> | <u>3,548</u> | 3,528        | 3,717        |
| Önerilen Yöntem | 3,355        | <b>3,715</b> | 3,929        | <b>2,044</b> | <b>3,260</b> | <b>3,326</b> | 3,902        |

Tablo 3.6’da Robust Retinex ve DeepUPE, DICM veri kümesinde en iyi NIQE değerini elde etmiştir. Zero-DCE ise ikinci en iyi NIQE değerini sağlamıştır. LIME veri kümesinde önerilen MT yöntemi en iyi NIQE değerine ulaşırken, EnlightenGAN ise ikinci en iyi değeri elde etmiştir. MEF veri kümesinde Zero-DCE ve EnlightenGAN sırasıyla en iyi ve ikinci en iyi NIQE sonucuna ulaşmıştır. VV veri kümesinde önerilen MT yöntemi en iyi NIQE değerine ulaşırken, Wang et al. ise ikinci en iyi değeri elde etmiştir. Benzer şekilde, NPE veri kümesinde önerilen MT yöntemi en iyi performansı sergilerken, Wang et al. ise ikinci en iyi performansı sergilemiştir. All Test Set veri kümesinde, en iyi ortalama NIQE değerini önerilen MT yöntemi elde etmiştir. EnlightenGAN ise çok az bir farkla ikinci en iyi değere ulaşmıştır. VE-LOL-H veri kümesinde en iyi NIQE değerini Zero-DCE, ikinci en iyi değeri EnlightenGAN yöntemi elde etmiştir.

Ortalama çalışma süresini hesaplayabilmek için  $625 \times 625 \times 3$  boyutlarında 20 adet görüntü seçilmiştir. Seçilen 20 görüntü üzerinde gerçekleşen toplam işlem süresi görüntü sayısına bölünerek ortalama süre elde edilmiştir. Yapılan tüm işlemler 2,3 GHz hızında 11. Nesil Intel Core i7-11800H MİB, 16 GB RAM ile Nvidia RTX 3060 6 GB GİB’e sahip bir kişisel bilgisayarda gerçekleştirilmiştir. Ortalama çalışma süresi ve eğitilebilir parametrelere ait sonuçlar Tablo 3.7’de sunulmuştur.

**Tablo 3.7.** Karşılaştırmada kullanılan yöntemlerin ortalama çalışma zamanı (sn) ve eğitilebilir parametrelerinin kıyaslanması.

| Yöntem          | Ortalama Çalışma Süresi | Eğitilebilir Parametre | Platform        |
|-----------------|-------------------------|------------------------|-----------------|
| SRİE            | 5,809                   | -                      | MATLAB(MİB)     |
| LIME            | 0,491                   | -                      | MATLAB(MİB)     |
| Robust Retinex  | 13,286                  | -                      | MATLAB(MİB)     |
| DeepUPE         | 0,965                   | 998.816                | Tensorflow(GİB) |
| EnlightenGAN    | 0,148                   | 8.636.675              | Pytorch(GİB)    |
| Zero-DCE        | 0,047                   | 79.416                 | Pytorch(GİB)    |
| Wang et al.     | 0,765                   | -                      | MATLAB(MİB)     |
| Önerilen Yöntem | 1,033                   | -                      | MATLAB(MİB)     |

Önerilen yöntemdeki MT ayrıştırma işlemi optimizasyon tabanlı bir yaklaşıma dayandığı için eğitilebilir parametreler içermez. Tablo 3.7’de görüldüğü gibi önerilen MT yönteminin iki seviyeli bir ayrıştırma prosedürü benimsediği için ortalama çalışma süresi diğer yöntemlere kıyasla biraz daha uzundur. Bununla birlikte, SRİE ve Robust Retinex’e göre önemli ölçüde daha hızlı bir çalışma süresi elde edilmiştir.

### 3.5.4. Bulgular

Önerilen MT tabanlı düşük aydınlıklı görüntü iyileştirme yöntemi, yapılan görsel ve nicel analizler sonucunda mevcut yöntemlere kıyasla dikkat çekici sonuçlar elde etmiştir. Uygulama çalışmaları, yöntemin her bileşeninin nihai iyileştirilmiş sonuca anlamlı katkılar sağladığını göstermiştir. Özellikle MT tabanlı ayrıştırma işlemi, detayların korunması ve gürültünün bastırılması açısından önemli bir rol oynamıştır. Ayrıca, iki seviyeli ayrıştırma PSNR değerlerinde önemli bir artış sağlayarak görsel kaliteye önemli katkılar sağlamıştır.

Görsel analizlerde, kıyaslamada kullanılan yöntemlerin sıklıkla karşılaştığı gürültü, aşırı parlama, doğal olmayan renk üretimi ve hale efektleri gibi sorunların büyük oranda önüne geçilmiştir. Karanlık alanlarda kalan ayrıntıların ortaya çıkarılması ve aydınlık alanlardaki renk dengesinin korunması önerilen MT yönteminin güçlü yönlerindendir. Nicel analizlerde, önerilen MT yöntemi çoğu veri kümesinde en iyi değerleri etmiştir. Referanssız veri kümelerinde ise dört veri kümesinde en iyi değerler elde edilmiştir. Verimlilik değerlendirmesi açısından işlem süresi bazı yöntemlere göre daha uzun olsa da elde edilen görsel ve nicel sonuçlar bu durumu dengeler niteliktedir.

Son olarak, önerilen MT yönteminin görsel ve nicel olarak tatmin edici sonuçlar üretmesine rağmen parlak nesnelerin ön planda olduğu sahnelerde aşırı iyileştirme eğilimindedir. Bu durum, detay kayıplarına ve aşırı parlamalara sebep olmaktadır. Önerilen MT yöntemi, parlaklık kontrolünde bazı sınırlılıklara sahiptir. Genel değerlendirmede, önerilen MT yöntemi hem görsel sonuçlar hem de performans ölçütlerine bağlı sonuçlarda literatürdeki birçok kendini kanıtlamış yöntemi geride bırakmıştır.


## 3.6. Önerilen NCC-PLM Yöntemi Sonuçları

Bu alt başlıkta, tez kapsamında önerilen “Düşük Aydınlıklı Görüntü İyileştirme İçin Yeni Renk Kanalı Odaklı Fiziksel Aydınlatma Modeli” adlı yönteme ait uygulama detayları, görsel sonuçlar, nicel sonuçlar ve bulgular verilmiştir.

### 3.6.1. Uygulama Detayları

Önerilen NCC-PLM yönteminin gama düzeltme işlemi için gama değeri, yeni renk kanalı önseli hesaplanması için yama boyutu ve karartma faktörü olmak üzere üç

parametrenin belirlenmesi gerekir. Bu amaçla, eşleştirilmiş görüntü kümelerinden rastgele 50 görüntü seçilerek parametre belirleme çalışmaları yapılmıştır. Optimum değerleri belirlemek için iyileştirilmiş görüntülerin ortalama PSNR değerleri referans alınmıştır. Şekil 3.18’de üç farklı parametrenin PSNR değerine etkisini gösteren grafikler sunulmuştur.




**Şekil 3.18.** Önerilen yöntemin parametre belirleme deneyleri. (a) Farklı görüntü kategorileri için gama değerlerinin etkisi, (b) karartma faktörünün etkisi, (c) yama boyutunun etkisi.

Şekil 3.18(a)’da üç farklı düşük aydınlıklı görüntü kategorisi için optimum gama değerleri; ekstra karanlık görüntüler için 0,4, karanlık görüntüler için 0,6 ve hafif karanlık görüntüler için 0,8 olarak belirlenmiştir. Şekil 3.18(b)’de görüldüğü gibi karartma faktörü en yüksek PSNR değerinin elde edildiği 0,2 olarak belirlenmiştir. Şekil 3.18(c)’de ise yama boyutunun PSNR üzerindeki etkisi verilmiştir. Buna göre optimum sonucu veren yama boyutu 31 olarak ayarlanmıştır.

### 3.6.2. Görsel Sonuçlar

Önerilen NCC-PLM yönteminin literatürdeki yöntemlere kıyasla üstün bir görsel kaliteye sahip olduğunu göstermek ve geçerliliğini kanıtlamak amacıyla farklı senaryolardaki düşük aydınlıklı görüntülere ait görsel sonuçlar verilmiştir. Bu görseller; iç mekan, gece vakti, kişi ve gündüz vakti olmak üzere dört kategoride sunulmuştur. İç mekan kategorisindeki görsel sonuçlar; Şekil 3.19’da “Tablo” görüntüsüne ait iyileştirme

sonuçları, Şekil 3.20’de “Müze” görüntüsüne ait iyileştirme sonuçları ve Şekil 3.21’de “Tiyatro” görüntüsüne ait iyileştirme sonuçları olarak sunulmuştur.



**Şekil 3.19.** Tablo görüntüsü için iyileştirme sonuçları.




**Şekil 3.20.** Müze görüntüsü için iyileştirme sonuçları.




**Şekil 3.21.** Tiyatro görüntüsü için iyileştirme sonuçları.

İç mekan görüntülerinde, SRIE, DeepUPE ve SCI yöntemleri yetersiz iyileştirme sonuçları üretmiştir. Tablo görüntüsünün sağ tarafı ve Müze görüntüsünün üst kısmında iyileştirmenin yetersiz olduğu açıkça görülmektedir. LIME, Robust Retinex ve Zero-DCE genel olarak iyi performans sergilemiştir. Ancak LIME renk sapmaları ve yoğun gürültüden muzdariptir. Zero-DCE, Tiyatro görüntüsündeki tahta kısımda görüldüğü gibi gürültüye neden olmuştur. Robust Retinex ise bazı bölgelerde yumuşatma etkisi oluşturmuştur. Jeon and Eom, Wang et al. ve GCP-MCS daha az karışıklığa sahip olan düşük pozlamalı sonuçlar üretmiştir. Diğer yöntemlerle kıyaslandığında, önerilen NCC-PLM yöntemi doğal renklere sahip görünümü ve yeterli aydınlık iyileştirmesi ile karşılaştırılan yöntemlerden iyi sonuçlar üretmiştir.


Gece vakti kategorisindeki görsel sonuçlar; Şekil 3.22’de “Şehir-1” görüntüsüne ait iyileştirme sonuçları, Şekil 3.23’te “Lunapark” görüntüsüne ait iyileştirme sonuçları ve Şekil 3.24’te “Anıt” görüntüsüne ait iyileştirme sonuçları olarak sunulmuştur.



Şekil 3.22. Şehir-1 görüntüsü için iyileştirme sonuçları.



Şekil 3.23. Lunapark görüntüsü için iyileştirme sonuçları.



**Şekil 3.24.** Anıt görüntüsü için iyileştirme sonuçları.

Gece vakti görüntülerinde, SRIE, DeepUPE ve SCI aydınlatma üzerinde yeterli iyileştirme yapamamıştır. LIME, Lunapark ve Anıt görüntülerinde görüleceği üzere aşırı parlak ve doğal olmayan renk üretimine sebep olmuştur. Robust Retinex, yetersiz aydınlatma iyileştirmesi ve yumuşatma sorunlarından muzdariptir. Zero-DCE ise Anıt görüntüsünde gökyüzü kısmında görüldüğü gibi doğal olmayan görünüme ve parlamalara neden olmuştur. Jeon and Eom, Wang et al. ve GCP-MCS yeterince aydınlık sonuçlar üretememiştir. Ayrıca, Anıt görüntüsünde ağaçların etrafında görülen hale etkilerine neden olmuştur. Önerilen NCC-PLM yöntemi, son derece karanlık bölgelerdeki ayrıntıları koruyarak tatmin edici sonuçlar üretmiştir. Dahası, herhangi bir bozulma ve gürültü oluşturmada doğal görünüme sahip sonuçlar üretmiştir.

Kişi kategorisindeki görsel sonuçlar; Şekil 3.25'te "Kişi-3" görüntüsüne ait iyileştirme sonuçları, Şekil 3.26'da "Kişi-4" görüntüsüne ait iyileştirme sonuçları ve Şekil 3.27'de "Kişi-5" görüntüsüne ait iyileştirme sonuçları olarak sunulmuştur.



Şekil 3.25. Kişi-3 görüntüsü için iyileştirme sonuçları.




Şekil 3.26. Kişi-4 görüntüsü için iyileştirme sonuçları.



**Şekil 3.27.** Kişi-5 görüntüsü için iyileştirme sonuçları.

Kişi görüntülerinde, DeepUPE ve SCI karanlık sonuçlar üretir. Şekil 3.26’da görüldüğü gibi arka planın görünürlüğü çok az artmıştır. LIME, Jeon and Eom ve Wang et al. gürültü ve bozulmaların sebep olduğu gerçekçi olmayan sonuçlar üretmiştir. Zero-DCE ve Wang et al. aşırı iyileştirme ile birlikte oluşan parlamalardan muzdariptir. Robust Retinex, üç görüntü için genel olarak iyi sonuçlar üretse de bazı bölgelerde oluşan yumuşatma etkisinin önüne geçememiştir. GCP-MCS, görüntülerde detay korumada başarısız olmuştur ve özellikle yüz bölgelerinde bariz renk bozulmalarına neden olmuştur. Önerilen NCC-PLM yöntemi, yeterli parlaklık iyileştirmesi sağlayarak renk sapması ve detay kaybolması olmadan görsel olarak iyi sonuçlar elde etmiştir.

Gündüz vakti kategorisindeki görsel sonuçlar; Şekil 3.28’de “Sokak-3” görüntüsüne ait iyileştirme sonuçları, Şekil 3.29’da “Arkadan Aydınlatmalı Görüntü-2” görüntüsüne ait iyileştirme sonuçları ve Şekil 3.30’de “Yol-2” görüntüsüne ait iyileştirme sonuçları olarak sunulmuştur.



Şekil 3.28. Sokak-3 görüntüsü için iyileştirme sonuçları.



Şekil 3.29. Arkadan Aydınlatmalı Görüntü-2 görüntüsü için iyileştirme sonuçları.



**Şekil 3.30.** Yol-2 görüntüsü için iyileştirme sonuçları.

Gündüz vakti görüntülerinde, DeepUPE daha koyu sonuçlar üretmiştir. Ayrıca, Şekil 3.30’da görüldüğü gibi görüntünün kenarlarında parlamalara sebep olmuştur. Zero-DCE, SCI ve Wang et al. aşırı iyileştirmeden muzdariptir. Dahası, Wang et al. Şekil 3.30’da bulut bölgesinde görülen aşırı iyileştirilmiş detaylar üretmiştir. SRIE, LIME, Jeon and Eom ve GCP-MCS sarı çayırları içeren bölgelerde açık bir şekilde görüldüğü üzere renk iyileştirmesi açısından iyi sonuçlar üretememiştir. Önerilen NCC-PLM yöntemine ek olarak, Robust Retinex tüm yöntemler arasında kesin referans görüntüsüne en yakın sonuçları üretmiştir. Ancak Şekil 3.30’da görüldüğü gibi gökyüzü bölgesindeki bazı detayları korumayı başaramamıştır. Önerilen NCC-PLM yöntemi, görüntüdeki detayları koruyarak kesin referans görüntüsüne en yakın sonuçları üretmiştir.

### 3.6.3. Nicel Sonuçlar

Tez kapsamında önerilen NCC-PLM yönteminin nicel analizinin nesnel bir şekilde yapılabilmesi için düşük aydınlıklı görüntü iyileştirme konusunda literatürde sıklıkla kullanılan performans ölçütleri kullanılmıştır. Düşük aydınlıklı görüntü iyileştirme performansını kapsamlı bir şekilde değerlendirmek için referanslı metrikler olan PSNR ve SSIM ile birlikte referanssız metrikler olan NIQE ve PIQE kullanılmıştır. Referanslı metriklerle ait nicel sonuçlar Tablo 3.8’de verilmiştir. Tablo 3.8’de, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.8.** Üç farklı veri kümesine ait referanslı metrik sonuçları.

| Yöntem          | Metrik | Veri Kümesi   |               |               |
|-----------------|--------|---------------|---------------|---------------|
|                 |        | Part2 Subset  | RELLISUR      | VE-LOL-L      |
| SRIE            | PSNR   | 14,416        | 12,344        | 13,601        |
|                 | SSIM   | 0,549         | 0,431         | 0,403         |
| LIME            | PSNR   | 16,178        | 13,736        | 13,479        |
|                 | SSIM   | 0,573         | 0,484         | 0,394         |
| Robust Retinex  | PSNR   | 15,197        | 13,742        | 14,091        |
|                 | SSIM   | 0,544         | <u>0,520</u>  | 0,394         |
| DeepUPE         | PSNR   | 14,426        | 12,750        | 13,530        |
|                 | SSIM   | <b>0,691</b>  | 0,382         | <u>0,403</u>  |
| Zero-DCE        | PSNR   | <u>16,572</u> | 14,920        | 14,271        |
|                 | SSIM   | 0,594         | 0,495         | 0,375         |
| SCI             | PSNR   | 15,962        | 14,056        | 8,524         |
|                 | SSIM   | 0,552         | 0,436         | 0,109         |
| Jeon and Eom    | PSNR   | 15,721        | 15,840        | 14,224        |
|                 | SSIM   | 0,552         | 0,453         | 0,371         |
| Wang et al.     | PSNR   | 16,517        | 15,527        | 13,006        |
|                 | SSIM   | <u>0,663</u>  | 0,486         | 0,381         |
| GCP-MCS         | PSNR   | 15,840        | <u>16,182</u> | <u>14,449</u> |
|                 | SSIM   | 0,654         | 0,473         | 0,384         |
| Önerilen Yöntem | PSNR   | <b>16,791</b> | <b>16,509</b> | <b>14,812</b> |
|                 | SSIM   | 0,613         | <b>0,531</b>  | <b>0,413</b>  |

Tablo 3.8’de, Part2 Subset veri kümesinde en iyi PSNR değerine önerilen NCC-PLM yöntemi, ikinci en iyi PSNR değerine ise Zero-DCE yöntemi ulaşmıştır. SSIM metriğinde ise en iyi değeri DeepUPE ve ikinci en iyi değeri Wang et al. elde etmiştir. RELISUR veri kümesinde, iki metrikte de en iyi sonuçlar önerilen NCC-PLM yöntemi ile elde edilmiştir. İkinci en iyi PSNR sonucuna GCP-MCS ve ikinci en iyi SSIM sonucuna Robust Retinex yöntemi ulaşmıştır. VE-LOL-L veri kümesinde, benzer şekilde önerilen NCC-PLM yöntemi en iyi metrik değerlerini elde etmiştir. GCP-MCS yöntemi, ikinci en iyi PSNR sonucuna ulaşırken DeepUPE ikinci en iyi SSIM sonucuna ulaşmıştır.

Referanssız metriklere ait nicel sonuçlar Tablo 3.9’da verilmiştir. Tablo 3.9’da, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.9.** Yedi farklı veri kümesine ait referanssız metrik sonuçları.

| Yöntem          | Metrik | Veri Kümesi   |               |               |               |               |               |               |
|-----------------|--------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
|                 |        | DICM          | LIME          | MEF           | VV            | NPE           | All Test Set  | VE-LOL-H      |
| SRIE            | NIQE   | 3,899         | 3,788         | <u>3,475</u>  | 2,850         | 3,986         | 3,650         | 3,538         |
|                 | PIQE   | 39,379        | <b>34,799</b> | 40,002        | 23,182        | <u>34,822</u> | 35,842        | 36,494        |
| LIME            | NIQE   | 3,846         | 4,155         | 3,720         | 2,489         | 4,268         | 3,629         | 3,954         |
|                 | PIQE   | <u>32,611</u> | 35,952        | 38,252        | <b>18,562</b> | 36,679        | <b>34,782</b> | 40,647        |
| Robust Retinex  | NIQE   | <b>3,238</b>  | 4,108         | 4,204         | 2,623         | 4,047         | 3,670         | 4,014         |
|                 | PIQE   | 42,339        | 47,049        | 55,668        | 86,211        | 41,865        | 49,019        | 64,883        |
| DeepUPE         | NIQE   | <b>3,238</b>  | 3,789         | 3,860         | 2,237         | 3,589         | 3,491         | <u>3,327</u>  |
|                 | PIQE   | <b>31,559</b> | 38,012        | 39,063        | 26,762        | 36,497        | 35,323        | <u>32,718</u> |
| Zero-DCE        | NIQE   | 3,309         | 4,045         | <b>3,123</b>  | 2,794         | 3,734         | 3,506         | <b>2,581</b>  |
|                 | PIQE   | 35,815        | 36,474        | <b>30,483</b> | 26,364        | 38,063        | 34,947        | <b>21,801</b> |
| SCI             | NIQE   | <u>3,254</u>  | <u>3,677</u>  | 3,718         | <b>1,931</b>  | 3,393         | <u>3,315</u>  | 3,489         |
|                 | PIQE   | 35,236        | <u>35,367</u> | 42,521        | 25,235        | 35,539        | 36,068        | 39,169        |
| Jeon and Eom    | NIQE   | 3,342         | 3,957         | 4,500         | <u>2,023</u>  | <u>3,376</u>  | 3,498         | 4,654         |
|                 | PIQE   | 37,047        | 37,350        | 40,490        | 21,071        | 36,618        | 36,186        | 46,044        |
| Wang et al.     | NIQE   | 3,479         | 3,925         | 4,087         | 2,098         | 3,548         | 3,528         | 3,717         |
|                 | PIQE   | 37,945        | 37,912        | <u>35,877</u> | 21,513        | 36,577        | 35,436        | 34,491        |
| GCP-MCS         | NIQE   | 3,486         | 4,083         | 4,324         | 2,080         | 3,647         | 3,626         | 3,778         |
|                 | PIQE   | 34,339        | 36,531        | 37,514        | <u>20,681</u> | 37,138        | 35,180        | 35,215        |
| Önerilen Yöntem | NIQE   | 3,364         | <b>3,587</b>  | 3,896         | 2,049         | <b>3,245</b>  | <b>3,302</b>  | 3,692         |
|                 | PIQE   | 37,158        | 36,243        | 40,594        | 21,839        | <b>33,458</b> | <u>34,804</u> | 40,590        |

Tablo 3.9’da, DICM veri kümesi için en iyi NIQE performansını Robust Retinex ve DeepUPE yöntemleri sergilemiştir. İkinci en iyi NIQE değeri ise SCI yöntem ile elde edilmiştir. PIQE metriği açısından en iyi sonuca DeepUPE yöntemi, ikinci en iyi sonuca ise LIME yöntemi ulaşmıştır. LIME veri kümesinde, en iyi NIQE değeri önerilen NCC-PLM yöntemi ile elde edilirken en iyi PIQE değeri SRIE yöntemi ile elde edilmiştir. Her iki metrikte de ikinci en iyi sonuca SCI yöntemi ulaşmıştır. MEF veri kümesinde, iki metrik açısından en iyi sonuçlar Zero-DCE yöntemi ile elde edilmiştir. İkinci en iyi NIQE değerini SRIE yöntemi, ikinci en iyi PIQE değerini ise Wang et al. elde etmiştir. VV veri kümesinde, NIQE metriğinde en iyi sonuca SCI, ikinci en iyi sonuca ise Jeon and Eom ulaşmıştır. PIQE metriğinde ise en iyi değeri LIME yöntemi, ikinci en iyi değeri GCP-MCS yöntemi elde etmiştir. NPE veri kümesinde, her iki metrik bakımından en iyi performansı önerilen NCC-PLM yöntemi sergilemiştir. İkinci en iyi NIQE değerine Jeon and Eom ve ikinci en iyi PIQE değerine SRIE yöntemi ulaşmıştır. Bu veri kümelerine ek olarak iki veri kümesinin daha kullanıldığı All Test Set kümesinde, önerilen NCC-PLM

yöntemi en iyi NIQE değerini elde etmiştir. İkinci en iyi NIQE sonucuna ise SCI yöntemi ulaşmıştır. PIQE metriğinde en iyi sonucu LIME yöntemi, ikinci en iyi sonucu ise önerilen NCC-PLM yöntemi elde etmiştir. VE-LOL-H veri kümesinde, her iki metrik açısından en iyi sonuçlar Zero-DCE yöntemi ile elde edilmiştir. DeepUPE yöntemi, iki referanssız metrikte de ikinci en iyi sonuçlara ulaşmıştır.

Son olarak, Tablo 3.10'da karşılaştırmada kullanılan yöntemlerin ortalama çalışma süresi ve eğitilebilir parametre sayısı ele alınmıştır. Ortalama çalışma süresini hesaplayabilmek için  $625 \times 625 \times 3$  boyutlarında 20 adet görüntü seçilmiştir. Seçilen 20 görüntü üzerinde gerçekleşen toplam işlem süresi görüntü sayısına bölünerek ortalama süre elde edilmiştir. Yapılan tüm işlemler 2,3 GHz hızında 11. Nesil Intel Core i7-11800H MİB, 16 GB RAM ile Nvidia RTX 3060 6 GB GİB'e sahip bir kişisel bilgisayarda gerçekleştirilmiştir.

**Tablo 3.10.** Ortalama çalışma zamanı (sn) ve eğitilebilir parametrelerin karşılaştırılması.

| Yöntem          | Ortalama Çalışma Süresi | Eğitilebilir Parametre | Platform        |
|-----------------|-------------------------|------------------------|-----------------|
| SRİE            | 5,809                   | -                      | MATLAB(MİB)     |
| LIME            | 0,491                   | -                      | MATLAB(MİB)     |
| Robust Retinex  | 13,286                  | -                      | MATLAB(MİB)     |
| DeepUPE         | 0,965                   | 998.816                | Tensorflow(GİB) |
| Zero-DCE        | 0,047                   | 79.416                 | Pytorch(GİB)    |
| SCI             | 0,019                   | 381                    | Pytorch(GİB)    |
| Jeon and Eom    | 0,096                   | -                      | Python(MİB)     |
| Wang et al.     | 0,765                   | -                      | MATLAB(MİB)     |
| GCP-MCS         | 0,091                   | -                      | Python(MİB)     |
| Önerilen Yöntem | 0.176                   | -                      | MATLAB(MİB)     |

Tablo 3.10'da görüldüğü gibi derin öğrenmeye dayalı yöntemler GİB hızlandırmalı hesaplama verimliliği sayesinde beklendiği üzere en düşük ortalama çalışma sürelerini sunmaktadır. Ancak eğitilebilir parametrelere sahip oldukları unutulmamalıdır. Önerilen NCC-PLM yöntemi, MİB platformunu kullanan yöntemlere kıyasla üçüncü en iyi ortalama çalışma süresi performansını sağlamıştır.

### 3.6.4. Bulgular

Önerilen yeni renk kanalı tabanlı fiziksel aydınlatma modeline dayalı yöntem, düşük aydınlıklı farklı veri kümeleri üzerinde test edilmiştir. Elde edilen görsel ve nicel bulgular, önerilen NCC-PLM yönteminin hem görsel hem de nicel açıdan başarılı sonuçlar ürettiğini ortaya koymaktadır. Görsel sonuçlar kapsamında, önerilen NCC-PLM

yönteminin düşük aydınlıklı sahnelerdeki ayrıntıları daha iyi ortaya çıkardığı, yeterli aydınlatma sağladığı ve renk bozulmalarını engellediği gözlemlenmiştir. Farklı senaryolarda yapılan kıyaslamalar ile birlikte diğer yöntemlerde görülen renk sapması, gürültü, detay kayıpları ve hale etkileri önemli ölçüde azaldığı ortaya konulmuştur.


Nicel sonuçlar kapsamında, üç farklı veri kümesi üzerinde yapılan referanslı karşılaştırma ile birlikte önerilen NCC-PLM yöntemi çoğu durumda rakip yöntemleri geride bırakmıştır. Ayrıca, referanssız değerlendirmede elde edilen sonuçlar, yöntemin doğal görüntü istatistikleriyle tutarlı sonuçlar ürettiğini göstermektedir. Ortalama çalışma süresi açısından, önerilen NCC-PLM yöntemi optimizasyon tabanlı yöntemlere göre çok daha hızlı, derin öğrenme tabanlı yöntemlere kıyasla ise biraz daha yavaş performans sergilemiştir. Sonuç olarak, önerilen yöntemin nicel sonuçlar, görsel kalite, detay koruma ve renk doğallığı açısından diğer yöntemlere sağladığı üstünlük güvenilir bir iyileştirme yaklaşımı olduğunu kanıtlamaktadır.

### 3.7. Önerilen ACGC Yöntemi Sonuçları

Bu alt başlıkta, tez kapsamında önerilen “Düşük Aydınlıklı Görüntü İyileştirme İçin Uyarlanabilir Krominans Gama Düzeltme” adlı yöntemle ait uygulama detayları, görsel sonuçlar, nicel sonuçlar ve bulgular verilmiştir.

#### 3.7.1. Uygulama Detayları


Önerilen ACGC yöntemi ile birlikte en iyi sonuçların elde edilebilmesi için parametre seçimi büyük önem arz etmektedir. Bu amaçla rastgele seçilen eşleştirilmiş gerçek dünya görüntüleri üzerinde bazı deneyler yapılmıştır. Uygulanan CLAHE işlemine ait parametreler üzerinde yapılan deneyler Şekil 3.31’de verilmiştir.



**Şekil 3.31.** Farklı CLAHE parametreleri için ortalama PSNR değerleri. (a) Blok boyutu, (b) kırpma limiti.

Şekil 3.31(a)'da görüldüğü gibi blok boyutu arttıkça ortalama PSNR değeri sürekli olarak azalmıştır. Bu sebeple blok boyutu 2 olarak seçilmiştir. Şekil 3.31(b)'de kırpma limiti parametresi üzerinde yapılan deneyde en iyi PSNR değeri, kırpma limitinin 0,012 olarak ayarlandığında elde edildiği gözlemlenmiştir.

Önerilen ACGC yönteminin GC, BLF-LS, LGC ve CLAHE gibi adımlarının etkisini görsel ve nicel olarak incelemek için deneysel çalışmalar yürütülmüştür. Bu amaçla, önerilen çerçevedeki her adımın etkisini göstermek için adımlar sırayla kaldırılarak iyileştirilmiş sonuçlar elde edilmiştir. Yapılan işlemler, RELLISUR veri kümesinden rastgele seçilen bir görüntü üzerinde gerçekleştirilmiştir. Elde edilen karşılaştırma sonuçları Şekil 3.32'de sunulmuştur.




**Şekil 3.32.** Her bir bileşenin sırayla çıkarılmasıyla elde edilen görsellerin karşılaştırılması. (a) Giriş görüntüsü, (b) kesin referans görüntüsü, (c) GC uygulanmadan elde edilen sonuç görüntüsü, (d) LGC uygulanmadan elde edilen sonuç görüntüsü, (e) BLF-LS uygulanmadan elde edilen sonuç görüntüsü, (f) CLAHE uygulanmadan elde edilen sonuç görüntüsü, (g) önerilen yöntem ile elde edilen sonuç görüntüsü.

Şekil 3.32'de görüldüğü gibi, GC uygulanmadan elde edilen sonuç giriş görüntüsüyle oldukça yakındır ve en düşük PSNR sonucunu vermiştir. LGC olmadan elde edilen sonuç, renk ve aydınlatma düzeltmelerini önerilen yöntem kadar etkili yapamamıştır. Önerilen çerçeveden BLF-LS çıkarılarak elde edilen sonuçta bazı detaylar

ortaya çıkarılamamış ve nihai çerçeveden 2,7 dB daha düşük bir sonuç elde etmiştir. Son olarak, CLAHE uygulanmadan elde edilen sonuçlarda karışıklık biraz daha düşüktür. Buradan hareketle, önerilen ACGC yönteminde her bir bileşenin iyileştirme sonucuna önemli bir katkı sağladığı sonucuna varılabilir.

### 3.7.2. Görsel Sonuçlar


Önerilen ACGC yönteminin görsel analizinin nesnel bir şekilde yapılabilmesi için literatürde sıklıkla kullanılan yöntemlerle kıyaslama yapılmıştır. Ayrıca sonuçları daha net görebilmek için görüntülerin bazı kısımları yakınlaştırılarak görüntülerin altında verilmiştir. Şekil 3.33'te “Düzensiz Aydınlatmalı Görüntü” görüntüsü için iyileştirme sonuçları verilmiştir.



Şekil 3.33. Düzensiz Aydınlatmalı Görüntü için iyileştirme sonuçları.

Şekil 3.33'te, SRIE, DeepUPE ve SCI yöntemleri karanlık alanları aydınlatmada iyi sonuçlar üretememiştir. Örneğin, bu sonuçlarda görüntünün sağ kısmında şapka takan kişi hala karanlıktır. LIME, renk bozulmaları ve ön sahnede duran kişinin etrafında oluşan hale etkilerinden muzdariptir. Wang et al. tüm sahneyi tam olarak aydınlatamamış ve bazı renk sapmalarının önüne geçememiştir. Önerilen ACGC yöntemi ile birlikte, Robust Retinex ve Zero-DCE görüntünün görünürlüğünü önemli derecede artırmıştır. Ancak Robust Retinex aşırı yumuşatılmış sonuçlar üretirken Zero-DCE gürültüyü artırmıştır. Önerilen ACGC yöntemi, parlak bölgelerde aşırı pozlamaya sebep olmadan karanlık bölgelerin parlaklığını önemli ölçüde artırmıştır.


Şekil 3.34'te “İç Mekan” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.34.** İç Mekan görüntüsü için iyileştirme sonuçları.

Şekil 3.34’te, DeepUPE ve SCI özellikle görüntünün sağ tarafındaki karanlık bölgede yeterli aydınlatma iyileştirmesi sağlayamamıştır. SRIE ve Wang et al. bazı karanlık bölgelerde görünürlük açısından tatmin edici olmayan sonuçlar üretmiştir. LIME, görüntünün bazı kısımlarında aşırı gürültü ve renk bozulmalarından muzdariptir. Robust Retinex iyi bir iyileştirme sonucu sunmasına rağmen yumuşatma etkisi sebebiyle bazı detayların kaybolmasına neden olmuştur. Zero-DCE ve önerilen yöntem tatmin edici sonuçlar üretmiştir. Ancak önerilen ACGC yöntemi ile Zero-DCE kıyaslandığında, önerilen ACGC yöntemi ön plandaki ahşap korkuluğun görünürlüğünü artırarak ve renk dengesini koruyarak üstün bir performans sergilemiştir.


Şekil 3.35’te “Şehir-2” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.35.** Şehir-2 görüntüsü için iyileştirme sonuçları.

Şekil 3.35’te, SRIE, DeepUPE ve SCI yöntemleri parlaklık açısından tatmin edici sonuçlar üretememiştir. Ayrıca, yeşil kutuda görüldüğü gibi Robust Retinex gökyüzü bölgesinde yumuşatma sorunundan muzdariptir. LIME, ufukta gerçekte olmayan renk geçişleri üretmiş ve görüntünün alt kısmındaki binanın sağ tarafında görülen parlamalara sebep olmuştur. Zero-DCE aşırı parlak ve gürültülü bir sonuç görüntüsü üretmiştir. Önerilen ACGC yöntemiyle karşılaştırıldığında, Zero-DCE ve Wang et al. biraz daha karanlık sonuçlar elde etmiştir. Önerilen ACGC yöntemi, uygun parlaklık iyileştirmesi sağlayarak ayrıntıları korumuştur.


Şekil 3.36’da “Ekstra Karanlık Görüntü” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.36.** Ekstra Karanlık Görüntü için iyileştirme sonuçları.

Şekil 3.36’da, iyileştirme işlemi sonrasında SCI dışındaki tüm yöntem sonuçlarında sahnenin ayrıntıları görünür hale gelmiştir. Ancak önerilen ACGC yöntemi ve Robust Retinex dışındaki tüm yöntemler yoğun gürültü üretmiştir. Robust Retinex ise kırmızı kutuda görüldüğü gibi ağaç dallarını yumuşatmıştır. Önerilen ACGC yöntemi, gürültü, renk bozulması ve parlama etkileri olmadan giriş görüntüsünün görünürliğini önemli ölçüde artırmıştır.


Şekil 3.37’de “Eyfel Kulesi-2” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.37.** Eyfel Kulesi-2 görüntüsü için iyileştirme sonuçları.

Şekil 3.37’de, daha önce de belirtildiği gibi SRIE, DeepUPE ve SCI yöntemleri diğer sonuçlara kıyasla daha koyu bir görünüm sergilemiştir. Zero-DCE ve Wang et al. kırmızı kutuda açık bir şekilde görüleceği üzere turuncu çiçekleri sarı renge dönüştürmüştür. Ayrıca, LIME ve Wang et al. yeşil kutuda görüldüğü gibi kulenin orta bölümünü aydınlatmada başarısız olmuştur. Buna karşılık, önerilen ACGC yöntemi uygun pozlamayı sağlayarak ve renk sapmalarının önüne geçerek tatmin edici sonuçlar üretmiştir.

Şekil 3.38’de “Arkadan Aydınlatmalı Görüntü-3” görüntüsü için iyileştirme sonuçları sunulmuştur.



**Şekil 3.38.** Arkadan Aydınlatmalı Görüntü-3 görüntüsü için iyileştirme sonuçları.

Şekil 3.38’de görüldüğü gibi SRIE, LIME, DeepUPE ve SCI yetersiz parlaklık iyileştirmesi sebebiyle düşük pozlamalı sonuçlar üretmiştir. Önerilen ACGC yöntemi ile birlikte Robust Retinex ve Zero-DCE tamir edici sonuçlar üretmiştir. Zero-DCE ve Wang et al. gürültülü sonuçlar üretmiştir. Yeşil kutuda görüldüğü gibi önerilen ACGC yöntemi, gürültüyü etkili bir şekilde bastırarak karanlıkta gizlenen detayları ortaya çıkarmıştır.

### 3.7.3. Nicel Sonuçlar

Tez kapsamında önerilen ACGC yönteminin nicel analizinin nesnel bir şekilde yapılabilmesi için düşük aydınlıklı görüntü iyileştirme konusunda literatürde sıklıkla kullanılan performans ölçütleri kullanılmıştır. Düşük aydınlıklı görüntü iyileştirme performansını kapsamlı bir şekilde değerlendirmek için referanslı metrikler olan PSNR ve SSIM ile birlikte referanssız metrik olan NIQE kullanılmıştır. Referanslı metriklerle ait nicel sonuçlar Tablo 3.11’de verilmiştir. Tablo 3.11’de, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.11.** İki farklı veri kümesine ait PSNR ve SSIM değerleri.

| Yöntem         | Metrik | Veri Kümesi   |              |
|----------------|--------|---------------|--------------|
|                |        | Part2 Subset  | RELLISUR     |
| SRIE           | PSNR   | 14,416        | 12,344       |
|                | SSIM   | 0,549         | 0,431        |
| LIME           | PSNR   | 16,178        | 13,736       |
|                | SSIM   | 0,573         | 0,484        |
| Robust Retinex | PSNR   | 15,197        | 13,742       |
|                | SSIM   | 0,544         | <u>0,520</u> |
| DeepUPE        | PSNR   | 14,426        | 12,750       |
|                | SSIM   | <b>0,691</b>  | 0,382        |
| Zero-DCE       | PSNR   | <u>16,572</u> | 14,920       |
|                | SSIM   | 0,594         | 0,495        |

**Tablo 3.11.** İki farklı veri kümesine ait PSNR ve SSIM değerleri (devamı).

|                 |      |               |               |
|-----------------|------|---------------|---------------|
| SCI             | PSNR | 15,962        | 14,056        |
|                 | SSIM | 0,552         | 0,436         |
| Wang et al.     | PSNR | 16,517        | <u>15,527</u> |
|                 | SSIM | 0,663         | 0,486         |
| Önerilen Yöntem | PSNR | <b>17,793</b> | <b>17,404</b> |
|                 | SSIM | <u>0,661</u>  | <b>0,528</b>  |

Tablo 3.11’de, Part2 Subset veri kümesinde en iyi PSNR değerini önerilen ACGC yöntemi ile elde edilmiştir. İkinci en iyi PSNR değeri ise Zero-DCE yöntemi ile elde edilmiştir. SSIM metriğinde ise en iyi sonuca DeepUPE ulaşırken ikinci en iyi sonuca önerilen ACGC yöntemi ulaşmıştır. RELLISUR veri kümesinde, iki metrikte de en iyi değerleri önerilen ACGC yöntemi elde etmiştir. İkinci en iyi PSNR sonucuna Wang et al. ulaşırken SSIM metriğinde, ikinci en iyi sonuca Robust Retinex ulaşmıştır.

NIQE metriğine ait nicel sonuçlar Tablo 3.12’de verilmiştir. Tablo 3.12’de, koyu sonuçlar en iyi sonucu temsil ederken altı çizili sonuçlar ikinci en iyi sonucu temsil etmektedir.

**Tablo 3.12.** Altı farklı veri kümesine ait NIQE değerleri.

| Yöntem          | Veri Kümesi  |              |              |              |              |              |
|-----------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                 | DICM         | LIME         | MEF          | VV           | NPE          | All Test Set |
| SRIE            | 3,899        | <u>3,788</u> | <u>3,475</u> | 2,850        | 3,986        | 3,650        |
| LIME            | 3,846        | 4,155        | 3,720        | 2,489        | 4,268        | 3,629        |
| Robust Retinex  | <b>3,238</b> | 4,108        | 4,204        | 2,623        | 4,047        | 3,670        |
| DeepUPE         | <b>3,238</b> | 3,789        | 3,860        | 2,237        | 3,589        | 3,491        |
| Zero-DCE        | 3,309        | 4,045        | <b>3,123</b> | 2,794        | 3,734        | 3,506        |
| SCI             | <u>3,254</u> | <b>3,677</b> | 3,718        | <b>1,931</b> | <u>3,393</u> | <b>3,315</b> |
| Wang et al.     | 3,479        | 3,925        | 4,087        | 2,098        | 3,548        | 3,528        |
| Önerilen Yöntem | 3,322        | 3,810        | 3,878        | <u>2,039</u> | <b>3,299</b> | <u>3,332</u> |

Tablo 3.12’de, DICM veri kümesinde en iyi değeri Robust Retinex ve DeepUPE yöntemleri elde ederken ikinci en iyi değeri SCI elde etmiştir. LIME veri kümesinde, en iyi sonuca SCI ulaşırken ikinci en iyi sonuca SRIE yöntemi ulaşmıştır. MEF veri kümesinde, en iyi sonucu ve ikinci en iyi sonucu sırasıyla Zero-DCE ve SRIE elde etmiştir. VV veri kümesinde, en iyi performansı SCI sergilerken ikinci en iyi performansı önerilen ACGC yöntemi sergilemiştir. NPE veri kümesinde, en iyi NIQE değerini önerilen ACGC yöntemi ve ikinci en iyi değeri ise SCI elde etmiştir. Önerilen ACGC yöntemi All Test Set veri kümesinde SCI yöntemini geçemese de sadece 0,017 gibi küçük bir farkla ikinci en iyi sonuca ulaşmıştır.

Son olarak, Tablo 3.13'te karşılaştırmada kullanılan yöntemlerin ortalama çalışma süresi ve eğitilebilir parametre sayısı sunulmuştur. Ortalama çalışma süresini hesaplayabilmek için  $625 \times 625 \times 3$  boyutlarında 20 adet görüntü rastgele seçilmiştir. Seçilen 20 görüntü üzerinde gerçekleşen toplam işlem süresi görüntü sayısına bölünerek ortalama süre elde edilmiştir. Yapılan tüm işlemler 2,3 GHz hızında 11. Nesil Intel Core i7-11800H MİB, 16 GB RAM ile Nvidia RTX 3060 6 GB GİB'e sahip kişisel bilgisayarda gerçekleştirilmiştir.

**Tablo 3.13.** Karşılaştırmada kullanılan yöntemlere ait ortalama çalışma zamanı (sn) ve eğitilebilir parametre değerleri.

| Yöntem          | Ortalama Çalışma Süresi | Eğitilebilir Parametre | Platform        |
|-----------------|-------------------------|------------------------|-----------------|
| SRİE            | 5,809                   | -                      | MATLAB(MİB)     |
| LİME            | 0,491                   | -                      | MATLAB(MİB)     |
| Robust Retinex  | 13,286                  | -                      | MATLAB(MİB)     |
| DeepUPE         | 0,965                   | 998.816                | Tensorflow(GİB) |
| Zero-DCE        | 0,047                   | 79.416                 | Pytorch(GİB)    |
| SCI             | 0,019                   | 381                    | Pytorch(GİB)    |
| Wang et al.     | 0,765                   | -                      | MATLAB(MİB)     |
| Önerilen Yöntem | 0,217                   | -                      | MATLAB(MİB)     |

Tablo 3.13'te, beklendiği üzere derin öğrenmeye dayalı yöntemlerden Zero-DCE ve SCI GİB hızlandırmalı hesaplama verimliliği sayesinde beklendiği üzere en düşük ortalama çalışma sürelerini sunmuştur. Önerilen ACGC yöntemi, MİB platformunu kullanan yöntemlere kıyasla en iyi ortalama çalışma süresi performansını sağlamıştır.

### 3.7.4. Bulgular

Önerilen uyarlanabilir krominans gama düzeltmesine dayalı yöntem, düşük aydınlıklı farklı veri kümeleri üzerinde test edilmiştir. Elde edilen görsel ve nicel bulgular, önerilen ACGC yönteminin hem görsel hem de nicel açıdan başarılı sonuçlar ürettiğini ortaya koymuştur. Görsel sonuçlar kapsamında, SRİE, DeepUPE ve SCI yöntemlerinin görüntülerdeki karanlık bölgeleri yeteri kadar aydınlatamadığı; LİME ve Wang et al. yöntemlerinin renk bozulmaları ve hale etkilerini engelleyemediği gözlemlenmiştir. Zero-DCE ve Robust Retinex başarılı sonuçlar üretmesine rağmen gürültü artışı ve yumuşatma gibi sorunların önüne geçememiştir. Önerilen ACGC yöntemi, karanlık alanlardaki ayrıntıları ortaya çıkarırken parlak bölgelerde oluşabilecek aşırı pozlama durumunun önüne geçmiş, daha dengeli renkler ve yeterli parlaklık iyileştirmesi sağlamıştır.

Nicel sonuçlar kapsamında, PSNR açısından iki veri kümesinde de en iyi değerler önerilen ACGC yöntemi ile elde edilmiştir. SSIM metriği açısından değerlendirildiğinde, önerilen ACGC yöntemi veri kümeleri genelinde diğer yöntemlere göre en iyi performansı sergilemiştir. Ayrıca, NIQE skorları da önerilen ACGC yönteminin farklı senaryolarda rekabetçi bir performans sergilediğini ve görsel kalite açısından güçlü bir alternatif oluşturduğunu göstermektedir. Çalışma süresi açısından GİB üzerinde çalışan yöntemler en iyi sonuçları vermiş olsa da önerilen ACGC yöntemi, MİB üzerinde çalışan yöntemler arasında en iyi ortalama çalışma süresini sağlamıştır.

Yapılan deneysel çalışmalar, yöntemin her bir bileşeninin iyileştirme sonuca önemli katkılar sunduğunu kanıtlamaktadır. Özellikle, GC ve BLF-LS işlemleri iyileştirme performansı üzerinde kritik katkılar sunmuştur. Sonuç olarak, önerilen ACGC yöntemi hem referanslı hem de referanssız değerlendirme metriklerinde iyi performans sergilemiştir. Görsel olarak iyi detay koruma, yeterli parlaklık iyileştirmesi ve daha doğal renkler sağlayarak etkili bir iyileştirme yöntemi olduğunu kanıtlamıştır.

### **3.8. Önerilen Yöntemlerin Değerlendirilmesi**

Bu bölümde detaylı bir şekilde hem görsel hem de nicel olarak incelenen dört yöntem, düşük aydınlıklı görüntülerin iyileştirilmesi problemine farklı perspektiflerden çözüm önermektedir. Önerilen tüm yöntemler, detayların korunması, gürültünün bastırılması ve ideal aydınlatma iyileştirmesi ile birlikte görsel kaliteyi artırma hedefini paylaşmıştır. Ancak kullandıkları kuramsal temeller, stratejiler, renk uzayı tercihleri ve verimlilik açısından farklılıklar içermektedir.

Önerilen SSIF yöntemi, HSV renk uzayında V bileşeni üzerinde yapılan işlemler ile birlikte düşük aydınlıklı görüntüleri iyileştirmiştir. Bu yöntem, hem genel karışıklığı artırmıştır hem de detayları güçlendirmiştir. Ancak bazı durumlarda, filtre parametrelerinden kaynaklı yapay görünüm ortaya çıkabilmektedir.

Önerilen MT yöntemi, benzer şekilde HSV renk uzayında V bileşeni üzerinde yapılan işlemler ile birlikte düşük aydınlıklı görüntüleri iyileştirmiştir. Yöntem, yerel karışıklığı artırsa da ön sahnede parlak nesnelerin bulunduğu bazı durumlarda aşırı iyileştirmeye sebep olabilmektedir.

Önerilen NCC yöntemi, fiziksel aydınlatma modelini esas almasıyla önceki yöntemlerden ayrılmıştır. Yöntem, görüntüye göre uyarlanabilir gama düzeltmesi

uygulamıştır. Ardından, çevresel aydınlık tahmini ve ışık saçılımı zayıflama oranı tahmini yapılarak iyileştirilmiş görüntü elde edilmiştir. Atmosferik saçılma etkilerini doğru bir şekilde modellemesi nedeniyle dış mekan sahnelerinde detay koruma ve renk doğallığı açısından güçlü bir performans sergilemiştir.

Önerilen ACGC yöntemi, YIQ renk uzayını kullanmasıyla önceki yöntemlerden ayrılmıştır. Bu yöntemde Y bileşeni ayrıştırılarak düşük ve yüksek frekanslı bileşenler ayrı ayrı iyileştirilmiştir. Ayrıca, I ve Q bileşenleri doğrudan yerel gama düzeltmesi ile iyileştirilmiştir. Böylece parlaklık ve renk bilgisi dengeli bir şekilde iyileştirilmiştir. Ancak bazı arkadan aydınlatmalı sahnelerde renk bozulmaları gözlemlenmektedir.

Nicel kıyaslamalar tüm yöntemlerin referanslı veri kümelerinde PSNR ve SSIM açısından rekabetçi olduklarını göstermektedir. En yüksek PSNR ve SSIM değerlerinin önerilen ACGC tarafından elde edildiği gözlemlenmiştir. Referanssız metrikler açısından bakıldığında, önerilen NCC-PLM yöntemi fiziksel modellemenin sağladığı avantaj ile daha iyi sonuçlar üretmiştir. Çalışma süresi açısından ise önerilen SSIF yöntemi en kısa ortalama çalışma süresine ulaşmıştır.

Sonuç olarak, incelenen dört yaklaşımdan her birinin farklı düşük aydınlık senaryolarında öne çıkan avantajlı yönlerinin olduğu gözlemlenmiştir. Her yöntem belirli koşullarda güçlü bir seçenek olmasına rağmen düşük aydınlıklı görüntü problemlerine daha iyi cevap veren NCC-PLM yöntemi ve ACGC yönteminin ön planda olduğu ifade edilebilir.

#### 4. SONUÇ VE ÖNERİLER

Düşük aydınlıklı görüntü iyileştirme, aydınlatma yetersizliğinden kaynaklanan bozulmaların önüne geçerek görüntülerin daha görünür, net ve kullanılabilir hale getirilmesini amaçlayan bir görüntü iyileştirme yöntemidir. Yetersiz aydınlatma koşulları düşük karşıtlık, renk bozulmaları, detay kaybı ve gürültü artışı gibi sorunlara neden olmaktadır. Bu sebeple düşük aydınlıklı görüntülerin iyileştirilmesi sadece görsel estetik için değil, aynı zamanda bilgisayarlı görü sistemlerinin güvenilirliği için de önemli bir gerekliliktir.

Düşük aydınlıklı görüntülerin iyileştirilmesi, günümüzde oldukça geniş uygulama alanlarında karşılık bulmaktadır. Akıllı telefon kameraları, gece görüş sistemleri, güvenlik kameraları, otonom araçlar ve insansız hava araçları gibi uygulama alanlarında düşük aydınlık koşullarında yakalanan görüntülerin iyileştirilmesi, yapılacak olan işlemin doğruluğunu ve güvenilirliğini doğrudan etkilemektedir. Dolayısıyla, düşük aydınlıklı görüntü iyileştirme konusunda yapılan araştırmalar hem endüstriyel çevrelerde hem de akademik toplulukta büyük bir ilgi görmektedir. Çalışmaların temel motivasyonu, insan gözünün algılayabileceği sınırları aşarak yakalanan görüntüleri daha kaliteli hale getirmektir.

Bu tez çalışması kapsamında, düşük aydınlıklı görüntülerin iyileştirilmesi üzerine dört farklı yöntem önerilmiştir. Bu yöntemler detaylı bir şekilde incelenmiş ve kapsamlı bir karşılaştırmalı değerlendirmeye tabi tutulmuştur. Her bir yöntem sunduğu teorik altyapı, renk uzayı tercihleri, kullanılan stratejiler, güçlü yönleri ve sınırlılıkları açısından detaylı bir şekilde incelenmiştir. Elde edilen bulgular ışığında dört yöntemin de görüntülerin görünürlüğünün artırılması, karşıtlığın iyileştirilmesi ve detay koruma noktasında başarılı olduğu söylenebilir. Ancak her dört yöntem de kullanılan yaklaşımın doğasından kaynaklanan farklı senaryolarda farklı avantajlara ve sınırlılıklara sahiptir.

Önerilen SSIF yöntemi, basit ve eğitim gerektirmeyen yapıya sahip olması nedeniyle hızlı ve pratik bir çözüm olarak öne çıkmaktadır. Önerilen çok ölçekli ayrıştırma ile elde edilen aydınlatma görüntüsü CLAHE ile iyileştirilmiştir. Böylece iyileştirilmiş görüntülerdeki gürültü artışının önüne geçilmiştir. Detay koruma ve gürültü bastırma açısından dengeli sonuçlar üretmiştir. Ancak karşıtlık iyileştirmesi açısından sınırlı bir iyileştirme performansı sergilemiştir. Bu nedenle, önerilen SSIF yöntemi düzensiz aydınlatmalı ve ekstra karanlık görüntülerde düşük gürültülü sonuçlar üretmesine rağmen

aydınlatma performansı açısından önerilen diğer yöntemlerin gerisinde kalmıştır. Bununla birlikte, yüksek parametre hassasiyeti yöntemin genellenebilirliğini kısıtlamıştır.

Önerilen MT yöntemi, karanlık bölgelerdeki ayrıntıları ortaya çıkarmada oldukça başarılıdır. Önerilen çok ölçekli MT ayrışımı ile elde edilen düşük ve yüksek frekanslı bileşenlere yerel gama düzeltme uygulanmıştır. Yerel gama düzeltme ile elde edilen iyileştirilmiş V bileşeni parlaklık ağırlık haritasının oluşturulmasında kullanılmıştır. Gama düzeltme uygulanan görüntüye parlaklık ağırlık haritası ile birlikte RGB uzayında işlem yapılması sebebiyle gürültü artışının önüne geçilememiştir. Bununla birlikte, ön sahnede parlak nesnelerin bulunduğu senaryolarda aşırı iyileştirilmiş sonuçlar üretme eğilimindedir. Parlaklık orantılı yaklaşım sayesinde düşük pozlamalı ve ekstra karanlık görüntüler üzerinde etkili bir iyileştirme performansı sergilemiştir.

Önerilen NCC-PLM yöntemi, fiziksel aydınlatma modeline dayalı olması ile önerilen diğer yöntemlerden ayrılmıştır. Önerilen yeni renk kanalı önseli ile birlikte renk koruma açısından iyi sonuçlar üretmiştir. Dış mekan ve atmosferik etkilerin yoğun olduğu senaryolarda başarılı sonuçlar elde etmiştir. Önerilen yöntem çevresel aydınlatma ve ışık saçılım zayıflama oranını tahmin ederek düşük aydınlıklı görüntüleri iyileştirmektedir. Çevresel aydınlatma tahmininin yeni renk kanalı önselinin en parlak piksellerini dikkate alarak yapılması sebebiyle düzensiz aydınlatmalı görüntülerdeki parlak bölgelerde detay iyileştirme açısından diğer yöntemlerin gerisinde kalmıştır.

Önerilen ACGC yöntemi, renk doğruluğu ve doğal görünümü ile ön plana çıkmıştır. I ve Q bileşenleri üzerinde yapılan işlemler krominans bilgisinin iyileştirilmesini sağlamıştır. Bu özelliği ile birlikte cilt tonları ve insan yüzleri açısından başarılı sonuçlar üretmiştir. Fakat arkadan aydınlatmalı senaryolarda krominans bilgisi üzerinde yapılan iyileştirme renk bozulmalarına sebep olmuştur. BLF-LS ile elde edilen detay katmanı üzerinde herhangi bir işlem yapılmaması sebebiyle detay iyileştirmesi açısından sınırlı bir performans sergilemiştir.

Karşılaştırmalı değerlendirmeler sonucunda, her senaryo için en iyi çözümün olmadığı ve önerilen her yöntemin farklı düşük aydınlık senaryosunda ön plana çıktığı gözlemlenmiştir. Önerilen SSIF yöntemi, düşük hesap maliyeti ve sadeliğiyle birlikte kaynak kısıtlı ortamlarda tercih edilecek ilk yöntemdir. Önerilen MT yöntemi ise karanlık bölgelerdeki detayların ön plana çıkarılmasının kritik öneme sahip olduğu durumlarda tercih edilmelidir. Önerilen NCC-PLM yöntemi, atmosferik etkilerin yoğun olduğu dış

mekan senaryolarında benimsenebilir. Önerilen ACGC yöntemi ise renk doğruluğunun önemli olduğu insan merkezli uygulamalarda öne çıkabilir. Değerlendirme sonuçları, düşük aydınlıklı görüntü iyileştirme probleminin sahne bağımlı bir yapısı olduğunu göstermektedir. Bu sebeple, farklı uygulamalar için farklı yaklaşımların benimsenmesi gerektiği açıktır.

Gelecek çalışmalar kapsamında odaklanılması düşünülen başlıca konular aşağıda sunulmuştur:

- Bu tez çalışması kapsamında yapılan detaylı çalışmalar neticesinde elde edilen bulgulara dayanarak farklı yöntemlerin güçlü yönleri benimsenerek daha dengeli hibrit algoritmaların geliştirilmesi hedeflenmektedir.
- Önerilen yöntemlerin hiçbiri derin öğrenme tabanlı değildir. Günümüzde derin öğrenme alanında önerilen farklı ağ yapılarının kullanılması ile birlikte daha esnek ve güçlü iyileştirme algoritmalarının geliştirilmesi hedeflenmektedir.
- Güvenlik kameraları ve otonom sürüş gibi gerçek zamanlı uygulamalar için düşük hesaplama maliyetine sahip ve gömülü sistemlere uygun algoritmaların geliştirilmesi hedeflenmektedir.
- Gelecek çalışmalarda farklı aydınlatma koşullarına sahip geniş veri kümeleri üzerinde yapılacak deneyler ile daha genellenebilir yöntemlerin geliştirilmesi hedeflenmektedir.
- Gelecekte önerilmesi hedeflenen yöntemlerin arkadan aydınlatmalı görüntüler, aşırı karanlık görüntüler ve düzensiz aydınlatmalı görüntüler gibi belirli senaryolara uyarlanması ile birlikte daha etkili iyileştirme sonuçlarının elde edilmesi hedeflenmektedir.

## KAYNAKÇA

- Aakerberg, A., Nasrollahi, K., & Moeslund, T. B. (2021, August). RELISUR: A real low-light image super-resolution dataset. In *Thirty-fifth Conference on Neural Information Processing Systems-NeurIPS 2021*.
- Aditya, K. P., Reddy, V. K., & Ramasangu, H. (2014). Enhancement technique for improving the reliability of disparity map under low light condition. *Procedia Technology*, 14, 236-243.
- Afifi, M., Derpanis, K. G., Ommer, B., & Brown, M. S. (2021). Learning multi-scale photo exposure correction. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 9157-9167).
- Ahmed, I., & Jeon, G. (2021). A real-time person tracking system based on SiamMask network for intelligent video surveillance. *Journal of Real-Time Image Processing*, 18(5), 1803-1814.
- Arbelaez, P., Maire, M., Fowlkes, C., & Malik, J. (2010). Contour detection and hierarchical image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 33(5), 898-916.
- Atoum, Y., Ye, M., Ren, L., Tai, Y., & Liu, X. (2020). Color-wise attention network for low-light image enhancement. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 506-507).
- Bertalmio, M., Caselles, V., & Provenzi, E. (2009). Issues about retinex theory and contrast enhancement. *International Journal of Computer Vision*, 83(1), 101-119.
- Boncellet, C. (2009). Image noise models. In *The essential guide to image processing* (pp. 143-167). Academic Press.
- Bychkovsky, V., Paris, S., Chan, E., & Durand, F. (2011, June). Learning photographic global tonal adjustment with a database of input/output image pairs. In *CVPR 2011* (pp. 97-104). IEEE.
- Cai, J., Gu, S., & Zhang, L. (2018). Learning a deep single image contrast enhancer from multi-exposure images. *IEEE Transactions on Image Processing*, 27(4), 2049-2062.
- Caimi, F. M., Kocak, D. M., & Justak, J. (2004, September). Remote visibility measurement technique using object plane data from digital image sensors. In *IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 5, pp. 3288-3291). IEEE.
- Chang, S. H., & Wu, H. H. P. (2013). Improved measurement of camera response function and its performance evaluation. *Applied optics*, 53(1), 82-89.
- Chen, C., Chen, Q., Xu, J., & Koltun, V. (2018). Learning to see in the dark. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3291-3300).
- Chen, J., Yang, L., Liu, W., Tian, X., & Ma, J. (2024). Lenfusion: a joint low-light enhancement and fusion network for nighttime infrared and visible image fusion. *IEEE Transactions on Instrumentation and Measurement*, 73, 1-15.

- Chen, Q., Xu, J., & Koltun, V. (2017). Fast image processing with fully-convolutional networks. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2497-2506).
- Chen, S. D., & Ramli, A. R. (2003a). Minimum mean brightness error bi-histogram equalization in contrast enhancement. *IEEE transactions on Consumer Electronics*, 49(4), 1310-1319.
- Chen, S. D., & Ramli, A. R. (2003b). Contrast enhancement using recursive mean-separate histogram equalization for scalable brightness preservation. *IEEE Transactions on consumer Electronics*, 49(4), 1301-1309.
- Chen, Y., Wen, C., Liu, W., & He, W. (2023). A depth iterative illumination estimation network for low-light image enhancement based on retinex theory. *Scientific Reports*, 13(1), 19709.
- Cheng, Y., Yan, J., & Wang, Z. (2019, September). Enhancement of weakly illuminated images by deep fusion networks. In *2019 IEEE international conference on image processing (ICIP)* (pp. 924-928). IEEE.
- Conde, M. H., Zhang, B., Kagawa, K., & Loffeld, O. (2016). Low-light image enhancement for multiaperture and multitap systems. *IEEE Photonics Journal*, 8(2), 1-25.
- Demir, Y., & Kaplan, N. H. (2023). Low-light image enhancement based on sharpening-smoothing image filter. *Digital Signal Processing*, 138, 104054.
- Demir, Y., Kaplan, N. H., Kucuk, S., & Severoglu, N. (2024). Pixel-wise low-light image enhancement based on metropolis theorem. *Journal of Visual Communication and Image Representation*, 102, 104211.
- Deng, G., Galetto, F., Al-nasrawi, M., & Waheed, W. (2021). A guided edge-aware smoothing-sharpening filter based on patch interpolation model and generalized gamma distribution. *IEEE Open Journal of Signal Processing*, 2, 119-135.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition* (pp. 248-255). IEEE.
- Everingham, M., Eslami, S. A., Van Gool, L., Williams, C. K., Winn, J., & Zisserman, A. (2015). The pascal visual object classes challenge: A retrospective. *International journal of computer vision*, 111(1), 98-136.
- Faramarzpour, N., Deen, M. J., Shirani, S., Fang, Q., Liu, L. W., de Souza Campos, F., & Swart, J. W. (2007). CMOS-based active pixel for low-light-level detection: analysis and measurements. *IEEE Transactions on Electron Devices*, 54(12), 3229-3237.
- Ferradans, S., Bertalmio, M., Provenzi, E., & Caselles, V. (2011). An analysis of visual adaptation and contrast perception for tone mapping. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(10), 2002-2012.
- Fu, X., Zeng, D., Huang, Y., Zhang, X. P., & Ding, X. (2016). A weighted variational model for simultaneous reflectance and illumination estimation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2782-2790).

- Ge, D. Y., Yao, X. F., Xiang, W. J., & Chen, Y. P. (2023). Vehicle detection and tracking based on video image processing in intelligent transportation system. *Neural Computing and Applications*, 35(3), 2197-2209.
- Gharbi, M., Chen, J., Barron, J. T., Hasinoff, S. W., & Durand, F. (2017). Deep bilateral learning for real-time image enhancement. *ACM Transactions on Graphics (TOG)*, 36(4), 1-12.
- Guo, C., Li, C., Guo, J., Loy, C. C., Hou, J., Kwong, S., & Cong, R. (2020). Zero-reference deep curve estimation for low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 1780-1789).
- Guo, J., Ma, J., García-Fernández, Á. F., Zhang, Y., & Liang, H. (2023). A survey on image enhancement for Low-light images. *Heliyon*, 9(4).
- Guo, X., Li, Y., & Ling, H. (2017). LIME: Low-light image enhancement via illumination map estimation. *IEEE Transactions on image processing*, 26(2), 982-993.
- Haghighat, M. B. A., Aghagolzadeh, A., & Seyedarabi, H. (2011). A non-reference image fusion metric based on mutual information of image features. *Computers & Electrical Engineering*, 37(5), 744-756.
- Hao, W., Ye, Z., Hong-Hai, S., & Jing-zhong, Z. (2017). Review of image enhancement algorithms. *Chinese Optics*, 10(4), 438-448.
- He, K., Sun, J., & Tang, X. (2010). Single image haze removal using dark channel prior. *IEEE transactions on pattern analysis and machine intelligence*, 33(12), 2341-2353.
- He, K., Sun, J., & Tang, X. (2012). Guided image filtering. *IEEE transactions on pattern analysis and machine intelligence*, 35(6), 1397-1409.
- Huang, W., Zhu, Y., & Huang, R. (2020). Low light image enhancement network with attention mechanism and retinex model. *IEEE Access*, 8, 74306-74314.
- Jeon, J. J. and Eom, I. K. 2022. Low-light image enhancement using inverted image normalized by atmospheric light. *Signal Processing*, 196, 108523.
- Jeon, J. J., Park, J. Y., & Eom, I. K. (2024). Low-light image enhancement using gamma correction prior in mixed color spaces. *Pattern Recognition*, 146, 110001.
- Jia, F., Wong, H. S., Wang, T., & Zeng, T. (2023). A reflectance re-weighted retinex model for non-uniform and low-light image enhancement. *Pattern Recognition*, 144, 109823.
- Jiang, H., Luo, A., Liu, X., Han, S., & Liu, S. (2024, September). Lightendiffusion: Unsupervised low-light image enhancement with latent-retinex diffusion models. In *European Conference on Computer Vision* (pp. 161-179). Cham: Springer Nature Switzerland.
- Jiang, K., Wang, Z., Wang, Z., Chen, C., Yi, P., Lu, T. and Lin, C. W. 2022. Degrade is upgrade: Learning degradation for low-light image enhancement, *AAAI Conference on Artificial Intelligence*, 36(1), 1078-1086.
- Jiang, Y., Gong, X., Liu, D., Cheng, Y., Fang, C., Shen, X., ... & Wang, Z. (2021). Enlightengan: Deep light enhancement without paired supervision. *IEEE transactions on image processing*, 30, 2340-2349.

- Jobson, D. J., Rahman, Z. U., & Woodell, G. A. (1997). Properties and performance of a center/surround retinex. *IEEE transactions on image processing*, 6(3), 451-462.
- Kaplan, N. H. 2018. Remote sensing image enhancement using hazy image model. *Optik*, 155, 139-148.
- Kaplan, N. H., & Erer, I. (2021). Scale aware remote sensing image enhancement using rolling guidance. *Journal of Visual Communication and Image Representation*, 80, 103315.
- Khan, M. F., Khan, E., & Abbasi, Z. A. (2014). Segment selective dynamic histogram equalization for brightness preserving contrast enhancement of images. *Optik*, 125(3), 1385-1389.
- Kim, H., Choi, S. M., Kim, C. S., & Koh, Y. J. (2021). Representative color transform for image enhancement. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 4459-4468).
- Kim, M., Park, D., Han, D. K., & Ko, H. (2014, January). A novel framework for extremely low-light video enhancement. In *2014 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 91-92). IEEE.
- Kim, Y. T. (1997). Contrast enhancement using brightness preserving bi-histogram equalization. *IEEE transactions on Consumer Electronics*, 43(1), 1-8.
- Kong, X. Y., Liu, L., & Qian, Y. S. (2021). Low-light image enhancement via poisson noise aware retinex model. *IEEE Signal Processing Letters*, 28, 1540-1544.
- Kucuk, S., Severoglu, N., Demir, Y., & Kaplan, N. H. (2025). New color channel driven physical lighting model for low-light image enhancement. *Digital Signal Processing*, 156, 104757.
- Land, E. H., & McCann, J. J. (1971). Lightness and retinex theory. *Journal of the Optical society of America*, 61(1), 1-11.
- Lee, C., Lee, C., & Kim, C. S. (2013). Contrast enhancement based on layered difference representation of 2D histograms. *IEEE transactions on image processing*, 22(12), 5372-5384.
- Lee, H. G., Yang, S., & Sim, J. Y. (2015, December). Color preserving contrast enhancement for low light level images based on retinex. In *2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)* (pp. 884-887). IEEE.
- Li, C., Guo, C., & Loy, C. C. (2021). Learning to enhance low-light image via zero-reference deep curve estimation. *IEEE transactions on pattern analysis and machine intelligence*, 44(8), 4225-4238.
- Li, C., Guo, J., Porikli, F., & Pang, Y. (2018). LightenNet: A convolutional neural network for weakly illuminated image enhancement. *Pattern recognition letters*, 104, 15-22.
- Li, D., Zhang, Y., Wen, P., & Bai, L. (2015, December). A retinex algorithm for image enhancement based on recursive bilateral filtering. In *2015 11th International Conference on Computational Intelligence and Security (CIS)* (pp. 154-157). IEEE.
- Li, L., Mu, X., Li, S., & Peng, H. (2020). A review of face recognition technology. *IEEE access*, 8, 139110-139120.

- Li, M., Liu, J., Yang, W., Sun, X., & Guo, Z. (2018). Structure-revealing low-light image enhancement via robust retinex model. *IEEE transactions on image processing*, 27(6), 2828-2841.
- Li, Q., Wu, H., Xu, L., Wang, L., Lv, Y., & Kang, X. (2020). Low-light image enhancement based on deep symmetric encoder–decoder convolutional networks. *Symmetry*, 12(3), 446.
- Li, X., Li, Q., Anisetti, M., Jeon, G., & Gao, M. (2024). A structure and texture revealing retinex model for low-light image enhancement. *Multimedia Tools and Applications*, 83(1), 2323-2347.
- Liu, J., Xu, D., Yang, W., Fan, M., & Huang, H. (2021). Benchmarking low-light image enhancement and beyond. *International Journal of Computer Vision*, 129(4), 1153-1184.
- Liu, M. Y., Breuel, T., & Kautz, J. (2017). Unsupervised image-to-image translation networks. *Advances in neural information processing systems*, 30.
- Liu, R., Ma, L., Zhang, J., Fan, X., & Luo, Z. (2021). Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 10561-10570).
- Liu, X., Xie, Q., Zhao, Q., Wang, H., & Meng, D. (2023). Low-light image enhancement by retinex-based algorithm unrolling and adjustment. *IEEE Transactions on Neural Networks and Learning Systems*, 35(11), 15758-15771.
- Loh, Y. P., & Chan, C. S. (2019). Getting to know low-light images with the exclusively dark dataset. *Computer vision and image understanding*, 178, 30-42.
- Lore, K. G., Akintayo, A., & Sarkar, S. (2017). LLNet: A deep autoencoder approach to natural low-light image enhancement. *Pattern Recognition*, 61, 650-662.
- Lu, K., & Zhang, L. (2020). TBEFN: A two-branch exposure-fusion network for low-light image enhancement. *IEEE Transactions on Multimedia*, 23, 4093-4105.
- Lukac, R., & Plataniotis, K. N. (Eds.). (2018). Color image processing: methods and applications. CRC press.
- Luo, Y., Lv, G., Ling, J., & Hu, X. (2025). Low-light image enhancement via an attention-guided deep Retinex decomposition model. *Applied Intelligence*, 55(2), 1-13.
- Lv, F., Lu, F., Wu, J., & Lim, C. (2018, September). MBLLEN: Low-light image/video enhancement using cnns. In *Bmvc* (Vol. 220, No. 1, p. 4).
- Ma, K., Zeng, K., & Wang, Z. (2015). Perceptual quality assessment for multi-exposure image fusion. *IEEE Transactions on Image Processing*, 24(11), 3345-3356.
- Ma, L., Liu, R., Zhang, J., Fan, X., & Luo, Z. (2022). Learning deep context-sensitive decomposition for low-light image enhancement. *IEEE Transactions on Neural Networks and Learning Systems*, 33(10), 5666-5680.
- Ma, L., Ma, T., Liu, R., Fan, X., & Luo, Z. (2022). Toward fast, flexible, and robust low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 5637-5646).

- Mao, X., Shen, C., & Yang, Y. B. (2016). Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections. *Advances in neural information processing systems*, 29.
- Martin, D., Fowlkes, C., Tal, D., & Malik, J. (2001, July). A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In *Proceedings eighth IEEE international conference on computer vision. ICCV 2001* (Vol. 2, pp. 416-423). IEEE.
- Matin, F., Jeong, Y., & Park, H. (2020). Retinex-based image enhancement with particle swarm optimization and multi-objective function. *IEICE TRANSACTIONS on Information and Systems*, 103(12), 2721-2724.
- Mittal, A., Soundararajan, R., & Bovik, A. C. (2012). Making a “completely blind” image quality analyzer. *IEEE Signal processing letters*, 20(3), 209-212.
- Morel, J. M., Petro, A. B., & Sbert, C. (2010). A PDE formalization of Retinex theory. *IEEE Transactions on Image Processing*, 19(11), 2825-2837.
- Nguyen, H., Tran, D., Nguyen, K., & Nguyen, R. (2023). Psenet: Progressive self-enhancement network for unsupervised extreme-light image enhancement. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (pp. 1756-1765).
- Omeiza, D., Webb, H., Jirotko, M., & Kunze, L. (2021). Explanations in autonomous driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(8), 10142-10162.
- Pan, X., Li, C., Pan, Z., Yan, J., Tang, S., & Yin, X. (2022). Low-light image enhancement method based on retinex theory by improving illumination map. *Applied Sciences*, 12(10), 5257.
- Park, S., Kim, K., Yu, S. and Paik, J., 2018. “Contrast enhancement for low-light image enhancement: A survey”, *IEIE Transactions on Smart Processing & Computing*, 7(1), 36-48.
- Park, S., Yu, S., Kim, M., Park, K., & Paik, J. (2018). Dual autoencoder network for retinex-based low-light image enhancement. *IEEE Access*, 6, 22084-22093.
- Pisano, E. D., Zong, S., Hemminger, B. M., DeLuca, M., Johnston, R. E., Muller, K., ... & Pizer, S. M. (1998). Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. *Journal of Digital imaging*, 11, 193-200.
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ... & Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer vision, graphics, and image processing*, 39(3), 355-368.
- Rahman, Z. U., Jobson, D. J., & Woodell, G. A. (1996, September). Multi-scale retinex for color image enhancement. In *Proceedings of 3rd IEEE international conference on image processing* (Vol. 3, pp. 1003-1006). IEEE.
- Raji, A., Thaibaoui, A., Petit, E., Bunel, P., & Mimoun, G. (1998). A gray-level transformation-based method for image enhancement. *Pattern Recognition Letters*, 19(13), 1207-1212.

- Ren, W., Liu, S., Ma, L., Xu, Q., Xu, X., Cao, X., ... & Yang, M. H. (2019). Low-light image enhancement via a deep hybrid network. *IEEE Transactions on Image Processing*, 28(9), 4364-4375.
- Ren, X., Yang, W., Cheng, W. H., & Liu, J. (2020). LR3M: Robust low-light enhancement via low-rank regularized retinex model. *IEEE Transactions on Image Processing*, 29, 5862-5876.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference*, Munich, Germany, October 5-9, 2015, proceedings, part III 18 (pp. 234-241). Springer International Publishing.
- Rudin, L. I., Osher, S., & Fatemi, E. (1992). Nonlinear total variation based noise removal algorithms. *Physica D: nonlinear phenomena*, 60(1-4), 259-268.
- Schaefer, G., & Stich, M. (2003, December). UCID: An uncompressed color image database. In *Storage and retrieval methods and applications for multimedia 2004* (Vol. 5307, pp. 472-480). SPIE.
- Severoglu, N., Demir, Y., Kaplan, N. H., & Kucuk, S. (2025). ACGC: Adaptive chrominance gamma correction for low-light image enhancement. *Journal of Visual Communication and Image Representation*, 107, 104402.
- Shen, L., Yue, Z., Feng, F., Chen, Q., Liu, S., & Ma, J. (2017). Msr-net: Low-light image enhancement using deep convolutional network. arXiv preprint arXiv:1711.02488.
- Shi, K., Feng, Y., Hu, T., Cao, Y., Wu, P., Liang, Y., ... & Yan, Q. (2025). FusionNet: Multi-model Linear Fusion Framework for Low-light Image Enhancement. In *Proceedings of the Computer Vision and Pattern Recognition Conference* (pp. 1028-1037).
- Singh, K., & Kapoor, R. (2014a). Image enhancement using exposure based sub image histogram equalization. *Pattern Recognition Letters*, 36, 10-14.
- Singh, K., & Kapoor, R. (2014b). Image enhancement via median-mean based sub-image-clipped histogram equalization. *Optik*, 125(17), 4646-4651.
- Tang, J. R., & Isa, N. A. M. (2014). Adaptive image enhancement based on bi-histogram equalization with a clipping limit. *Computers & Electrical Engineering*, 40(8), 86-103.
- Tang, L., Xiang, X., Zhang, H., Gong, M., & Ma, J. (2023). DIVFusion: Darkness-free infrared and visible image fusion. *Information Fusion*, 91, 477-493.
- Tao, L., Zhu, C., Song, J., Lu, T., Jia, H., & Xie, X. (2017, September). Low-light image enhancement using CNN and bright channel prior. In *2017 IEEE International Conference on Image Processing (ICIP)* (pp. 3215-3219). IEEE.
- Vaswani, A. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*.
- Veluchamy, M., & Subramani, B. (2025). Detail preserving noise aware retinex model for low light image enhancement. *Journal of Optics*, 1-16.

- Venkatanath, N., Praneeth, D., Sumohana, S. C., & Swarup, S. M. (2015, February). Blind image quality evaluation using perception based features. In *2015 twenty first national conference on communications (NCC)* (pp. 1-6). IEEE.
- Vijayalakshmi, D., Nath, M. K., & Acharya, O. P. (2020). A comprehensive survey on image contrast enhancement techniques in spatial domain. *Sensing and Imaging*, 21(1), 40.
- Vonikakis, V., Kouskouridas, R., & Gasteratos, A. (2018). On the evaluation of illumination compensation algorithms. *Multimedia Tools and Applications*, 77(8), 9211-9231.
- Wang, H., Xu, K., & Lau, R. W. (2022, October). Local color distributions prior for image enhancement. In *European Conference on Computer Vision* (pp. 343-359). Cham: Springer Nature Switzerland.
- Wang, J., Tan, W., Niu, X., & Yan, B. (2019, July). RDGAN: Retinex decomposition based adversarial learning for low-light enhancement. In *2019 IEEE international conference on multimedia and expo (ICME)* (pp. 1186-1191). IEEE.
- Wang, L., Fu, G., Jiang, Z., Ju, G., & Men, A. (2019, July). Low-light image enhancement with attention and multi-level feature fusion. In *2019 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)* (pp. 276-281). IEEE.
- Wang, R., Zhang, Q., Fu, C. W., Shen, X., Zheng, W. S., & Jia, J. (2019). Underexposed photo enhancement using deep illumination estimation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 6849-6857).
- Wang, S., Zheng, J., Hu, H. M., & Li, B. (2013). Naturalness preserved enhancement algorithm for non-uniform illumination images. *IEEE transactions on image processing*, 22(9), 3538-3548.
- Wang, W., Chen, Z., Yuan, X., & Wu, X. (2019). Adaptive image enhancement method for correcting low-illumination images. *Information Sciences*, 496, 25-41.
- Wang, W., Wei, C., Yang, W., & Liu, J. (2018, May). Gladnet: Low-light enhancement network with global awareness. In *2018 13th IEEE international conference on automatic face & gesture recognition (FG 2018)* (pp. 751-755). IEEE.
- Wang, W., Wu, X., Yuan, X. and Gao, Z., 2020. An experiment-based review of low-light image enhancement methods. *IEEE Access*, 8, pp.87884-87917.
- Wang, W., Yan, D., Wu, X., He, W., Chen, Z., Yuan, X., & Li, L. (2023). Low-light image enhancement based on virtual exposure. *Signal Processing: Image Communication*, 118, 117016.
- Wang, W., Yang, H., Fu, J., & Liu, J. (2024). Zero-reference low-light enhancement via physical quadruple priors. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 26057-26066).
- Wang, X., Wang, Y., Zhou, J., Liu, J., Gao, Y., Wang, Y., & Zheng, J. (2025). An unsupervised learning method based on U-Net++ for low-light image enhancement. *Signal, Image and Video Processing*, 19(4), 282.
- Wang, Y., Chen, Q., & Zhang, B. (1999). Image enhancement based on equal area dualistic sub-image histogram equalization method. *IEEE Transactions On Consumer Electronics*, 45(1), 68-75.

- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions On Image Processing*, 13(4), 600-612.
- Wei, C., Wang, W., Yang, W., & Liu, J. (2018). Deep retinex decomposition for low-light enhancement. arXiv preprint arXiv:1808.04560.
- Wu, W., Weng, J., Zhang, P., Wang, X., Yang, W., & Jiang, J. (2022). Uretinex-net: Retinex-based deep unfolding network for low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 5901-5910).
- Xie, Z., Ren, H., Huang, J., He, Z., Lu, H., Liu, Y., ... & Xie, C. (2025). Low-Light Image Enhancement via Multi-Exposure Progressive Contrastive Regularization. *IEEE Transactions on Circuits and Systems for Video Technology*.
- Xiong, W., Liu, D., Shen, X., Fang, C., & Luo, J. (2022, August). Unsupervised low-light image enhancement with decoupled networks. In *2022 26th International Conference on Pattern Recognition (ICPR)* (pp. 457-463). IEEE.
- Xu, Y., Yang, C., Sun, B., Yan, X., & Chen, M. (2021). A novel multi-scale fusion framework for detail-preserving low-light image enhancement. *Information Sciences*, 548, 378-397.
- Yang, J., Min, Q., Lu, W., Ma, Y., Yao, W., & Lu, T. (2017). An RGB channel operation for removal of the difference of atmospheric scattering and its application on total sky cloud detection. *Atmospheric Measurement Techniques*, 10(3), 1191-1201.
- Yang, S., Zhou, D., Cao, J., & Guo, Y. (2023). LightingNet: An integrated learning method for low-light image enhancement. *IEEE Transactions on Computational Imaging*, 9, 29-42.
- Yang, W., Wang, S., Fang, Y., Wang, Y., & Liu, J. (2020). From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 3063-3072).
- Yang, W., Wang, W., Huang, H., Wang, S., & Liu, J. (2021). Sparse gradient regularized deep retinex network for robust low-light image enhancement. *IEEE Transactions on Image Processing*, 30, 2072-2086.
- Yin, L., Wang, L., Li, J., Lu, S., Tian, J., Yin, Z., ... & Zheng, W. (2023). YOLOV4\_CSPBi: enhanced land target detection model. *Land*, 12(9), 1813.
- Ying, Z., Li, G., Ren, Y., Wang, R., & Wang, W. (2017). A new low-light image enhancement algorithm using camera response model. In *Proceedings of the IEEE international conference on computer vision workshops* (pp. 3015-3022).
- Yu, F., Chen, H., Wang, X., Xian, W., Chen, Y., Liu, F., ... & Darrell, T. (2020). Bdd100k: A diverse driving dataset for heterogeneous multitask learning. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 2636-2645).
- Yu, R., Liu, W., Zhang, Y., Qu, Z., Zhao, D., & Zhang, B. (2018). Deepexposure: Learning to expose photos with asynchronously reinforced adversarial learning. *Advances in neural information processing systems*, 31.

- Yu, W., Yao, H., Li, D., Li, G., & Shi, H. (2021). GLAGC: Adaptive dual-gamma function for image illumination perception and correction in the wavelet domain. *Sensors*, 21(3), 845.
- Yu, X., Dai, P., Li, W., Ma, L., Shen, J., Li, J., & Qi, X. (2022, October). Towards efficient and scale-robust ultra-high-definition image demoiréing. In *European Conference on Computer Vision* (pp. 646-662). Cham: Springer Nature Switzerland.
- Zhai, G., Sun, W., Min, X., & Zhou, J. (2021). Perceptual quality assessment of low-light image enhancement. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 17(4), 1-24.
- Zhang, C., Yan, Q., Zhu, Y., Li, X., Sun, J., & Zhang, Y. (2020, July). Attention-based network for low-light image enhancement. In *2020 IEEE International Conference on Multimedia and Expo (ICME)* (pp. 1-6). IEEE.
- Zhang, Y., Di, X., Zhang, B., & Wang, C. (2020). Self-supervised image enhancement network: Training with low light images only. arXiv preprint arXiv:2002.11300.
- Zhang, Y., Guo, X., Ma, J., Liu, W., & Zhang, J. (2021). Beyond brightening low-light images. *International Journal of Computer Vision*, 129, 1013-1037.
- Zhang, Y., Zhang, J., & Guo, X. (2019, October). Kindling the darkness: A practical low-light image enhancer. In *Proceedings of the 27th ACM international conference on multimedia* (pp. 1632-1640).
- Zhang, Z., Sun, W., Min, X., Zhu, W., Wang, T., Lu, W., & Zhai, G. (2021, July). A No-Reference Evaluation Metric for Low-Light Image Enhancement. In *ICME* (pp. 1-6).
- Zhao, H., Shi, J., Qi, X., Wang, X., & Jia, J. (2017). Pyramid scene parsing network. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2881-2890).
- Zhou, L., Chen, X., Ye, B., Jiang, X., Zou, S., Ji, L., ... & Wang, T. (2025). A low-light image enhancement method based on HSV space. *The Imaging Science Journal*, 73(1), 16-29.
- Zhu, A., Zhang, L., Shen, Y., Ma, Y., Zhao, S., & Zhou, Y. (2020, July). Zero-shot restoration of underexposed images via robust retinex decomposition. In *2020 IEEE International Conference on Multimedia and Expo (ICME)* (pp. 1-6). IEEE.
- Zhu, M., Pan, P., Chen, W., & Yang, Y. (2020, April). Eemefn: Low-light image enhancement via edge-enhanced multi-exposure fusion network. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 34, No. 07, pp. 13106-13113).

## TEZDEN ÜRETİLEN YAYINLAR

### 1. Makaleler

- Demir, Y., & Kaplan, N. H. (2023). Low-light image enhancement based on sharpening-smoothing image filter. *Digital Signal Processing*, 138, 104054.
- Demir, Y., Kaplan, N. H., Kucuk, S., & Severoglu, N. (2024). Pixel-wise low-light image enhancement based on metropolis theorem. *Journal of Visual Communication and Image Representation*, 102, 104211.
- Kucuk, S., Severoglu, N., Demir, Y., & Kaplan, N. H. (2025). New color channel driven physical lighting model for low-light image enhancement. *Digital Signal Processing*, 156, 104757.
- Severoglu, N., Demir, Y., Kaplan, N. H., & Kucuk, S. (2025). ACGC: Adaptive chrominance gamma correction for low-light image enhancement. *Journal of Visual Communication and Image Representation*, 107, 104402.

### 2. Bildiriler

- Demir, Y., & Kaplan, N. H. (2025). Belirginlik-Odaklı Sanal Pozlamaya Dayalı Düşük-Aydınlıklı Görüntü İyileştirme. *11th International Symposium on Intelligent Technologies in Engineering and Science (ISITES 2025)*, 6 (2), 337-346.

### 3. Diğer Makaleler

- Demir, Y., Severoğlu, N., Kaplan, N. H., & Küçük, S. (2025). Classification of Images in Bad Weather Conditions with Convolutional Neural Networks. *Balkan Journal of Electrical and Computer Engineering*, 13(1), 39-46.

### 4. Diğer Bildiriler

- Demir, Y., & Kaplan, N. H. (2021). An Iterative Method Based on Hazy Image Model for Remote Sensing Image Enhancement. *2021 2th International Symposium on Applied Sciences and Engineering (ISASE2021)*, 238-241.
- Kılıç, U., Demir, Y., Kaplan, N. H., & Tümöklü Özyer, G. (2021) Recognition of Electronic Circuit Components Using a Modern Convolutional Object Detector. *International Conference on Advances in Engineering, Architecture, Science and Technology(ICA-EAST2021)*, 271-278.
- Demir, Y., Yıldırım, Ö.F., & Küçük, S. (2023). YOLOv5 ile Deprem Uydu Görüntülerinden Yıkılan Binaların Tespiti: Kahramanmaraş Örneği. *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) XII. Teknik Sempozyumu*, 89.
- Kaplan, N. H., Kucuk, S., Severoglu, N., & Demir, Y. (2025). Virtual Exposure Based Underwater Image Enhancement. *11th International Symposium on Intelligent Technologies in Engineering and Science 2025 (ISITES2025)*, 411-420.