

Enhancing the Quality of Satellite Images in Disaster Management: A Comparative Analysis of Zero-DCE, CIDNet, and MIRNet Models

Mehmet Umut SALUR ¹ , Cagri KARAKAS ² , İlhan AYDIN ² 

¹ Gaziantep Islam Science and Technology University, Faculty of Engineering and Natural Sciences, Department of Computer Engineering, 27010 Gaziantep, Türkiye

² Firat University, Faculty of Engineering, Department of Computer Engineering, 23180 Elazig, Türkiye

Keywords

Low-light image enhancement, Deep learning, Zero-DCE, CIDNet, MIRNet

Highlights

- * Comparative analysis of Zero-DCE, CIDNet, and MIRNet for satellite image enhancement
- * Potential of deep learning-based image enhancement methods for disaster management
- * MIRNet's outstanding performance in color and brightness enhancement

Aim

This study aims to assess deep learning methods for enhancing low-light satellite images

Location

Şahinbey, Gaziantep

Methods

The performance of Zero-DCE, CIDNet, and MIRNet models was analyzed using images obtained from the Hatay region following the February 6, 2023 earthquakes in Türkiye

Results

CIDNet excels in structural accuracy, MIRNet in color enhancement, and Zero-DCE in quick brightness improvement, each serving distinct disaster management needs

Supporting Institutions

The author(s) declared that this study has used no support data from other institutions

Financial Disclosure

This study was supported by the Scientific and Technological Research Council of Turkey (TUBITAK) under Project No:123E669

Peer-review

Externally peer-reviewed

Conflict of Interest

The authors have no conflicts of interest to declare

How to cite:

Salur M.U., Karakas C., Aydın I., 2025. Enhancing the Quality of Satellite Images in Disaster Management: A Comparative Analysis of Zero-DCE, CIDNet, and MIRNet Models, Turk Deprem Arastirma Dergisi 7(1), 101-114, DOI:10.46464/tdad.1600376.

Manuscript

Research Article

Received: 12.12.2024

Revised: 21.01.2025

Accepted: 29.01.2025

Printed: 30.04.2025

DOI

10.46464/tdad.1600376

Corresponding Author

Mehmet Umut Salur

Email: mehmetumut.salur@gibtu.edu.tr



Content of this journal is licensed under a Creative Commons Attribution 4.0 International Non-Commercial License




Figure
Results of image enhancement models on an image in ITU UHUZAM dataset

Doğal Afet Yönetiminde Uydu Görüntülerinin Kalitesinin İyileştirilmesi: Zero-DCE, CIDNet ve MIRNet Modellerinin Karşılaştırmalı Analizi

Mehmet Umut SALUR ¹ , Çağrı KARAKAŞ ² , İlhan AYDIN ²

¹ Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, 27010 Gaziantep, Türkiye

² Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 23180 Elazığ, Türkiye

ÖZET

Doğal afetlerde uydu görüntüleri, afet yönetimi ve kurtarma operasyonlarında kritik bir rol oynamaktadır. Ancak düşük ışık koşullarında elde edilen bu görüntüler, gürültü ve detay kaybı nedeniyle analizlerde zorluk yaratmaktadır. Bu çalışmada, düşük ışık uydu görüntülerinin iyileştirilmesinde Zero-DCE, CIDNet ve MIRNet modellerinin performansları değerlendirilmiştir. Hatay bölgesine ait deprem sonrası uydu görüntüleri kullanılarak modellerin PSNR, SSIM ve LPIPS gibi metriklerle performansları analiz edilmiştir. Ayrıca modellerin bir kıyaslama veri kümesindeki başarımları da analiz edilmiştir. Sonuçlar, CIDNet'in detay ve yapısal doğrulukta üstün olduğunu, MIRNet'in ise renk ve parlaklık iyileştirme konusunda başarılı olduğunu göstermiştir. Zero-DCE, parlaklık artırmada etkili olsa da yapısal doğrulukta diğer modellere göre geride kalmıştır. Bu çalışmada derin öğrenme tabanlı görüntü iyileştirme modellerinin afet yönetimindeki kullanım potansiyeli ve etkili oldukları görüntü özellikleri ortaya konulmuştur.

Anahtar Kelimeler

Düşük ışık görüntü iyileştirme, Derin öğrenme, Zero-DCE, CIDNet, MIRNet

Öne Çıkanlar

- * Uydu görüntüleri iyileştirilmesinde Zero-DCE, CIDNet ve MIRNet modelleri karşılaştırması
- * Derin öğrenme tabanlı görüntü iyileştirme yöntemlerin afet yönetimi için potansiyelini
- * MIRNet, renk ve parlaklık iyileştirme konusunda üstün başarı

Makale

Araştırma Makalesi

Geliş: 12.12.2024

Düzeltilme: 21.01.2025

Kabul: 29.01.2025

Basım: 30.04.2025

DOI

10.46464/tdad.1600376

Sorumlu yazar

Mehmet Umut Salur

E-posta:

mehmetumut.salur@gibtu.edu.tr

Enhancing the Quality of Satellite Images in Disaster Management: A Comparative Analysis of Zero-DCE, CIDNet, and MIRNet Models

Mehmet Umut SALUR ¹ , Cagri KARAKAS ² , İlhan AYDIN ²

¹ Gaziantep Islam Science and Technology University, Faculty of Engineering and Natural Sciences, Department of Computer Engineering, 27010 Gaziantep, Türkiye

² Fırat University, Faculty of Engineering, Department of Computer Engineering, 23180 Elazığ, Türkiye

ABSTRACT

Satellite images play a critical role in disaster management and rescue operations in natural disasters. However, these images create difficulties in analysis due to noise and loss of detail. This study evaluates the performance of deep learning models—Zero-DCE, CIDNet, and MIRNet—in enhancing low-light satellite images. The performances of the models were analyzed with metrics such as PSNR, SSIM and LPIPS using post-earthquake satellite images of the Hatay region. In addition, the performance of the models on a benchmark dataset was analyzed. The results showed that CIDNet was superior in detail and structural accuracy, while MIRNet was successful in color and brightness enhancement. Although Zero-DCE was effective in brightness enhancement, it lagged behind other models in structural accuracy. In this study, the potential of deep learning-based image enhancement models in disaster management and the image features on which they are effective were revealed.

Keywords

Low-light image enhancement, Deep learning, Zero-DCE, CIDNet, MIRNet

Highlights

- * Comparative analysis of Zero-DCE, CIDNet, and MIRNet for satellite image enhancement
- * Potential of deep learning-based image enhancement methods for disaster management
- * MIRNet's outstanding performance in color and brightness enhancement

Manuscript

Research Article

Received: 12.12.2024

Revised: 21.01.2025

Accepted: 29.01.2025

Printed: 30.04.2025

DOI

10.46464/tdad.1600376

Corresponding Author

Mehmet Umut Salur

Email:

mehmetumut.salur@gibtu.edu.tr

1. GİRİŞ

Doğal afetlerde, durumun hızlı ve etkili bir şekilde değerlendirilmesi, afet yönetimi ve kurtarma operasyonlarının başarısını doğrudan belirleyen kritik bir unsurdur. Bu değerlendirme süreci, sahadan elde edilen görsel verilerin etkin kullanımına dayanır. Bu bağlamda, uydu görüntüleri, afet bölgelerinin geniş kapsamlı ve hızlı analizinde değerli bir veri kaynağı sunmaktadır. Bununla birlikte, düşük ışık koşulları veya olumsuz hava şartları gibi çevresel faktörler, bu görüntülerin elde edilmesini ve işlenmesini zorlaştırarak veri analiz süreçlerini etkileyebilmektedir.

Görüntü edinimi sırasında, genellikle farklı şiddette bozulmalar meydana gelebilir. Bu, kameraların fiziksel sınırlamalarından veya uygunsuz hava ve ışık koşullarından kaynaklanabilmektedir (Zamir ve diğ. 2020). Görüntü edinme süreci oldukça karmaşıktır ve birçok faktörün etkisiyle çeşitli kusurlar meydana gelebilir. Özellikle kapalı alanlar, bulutlu hava veya gece gibi yetersiz aydınlatma koşulları, görüntü kalitesinde belirgin düşüslere neden olmaktadır (Park ve diğ. 2018). Görüntülerin genel olarak karanlık bir yapıya sahip olması, detayların bulanık ve kontrastın düşük olması, yalnızca görsel bilginin elde edilmesini zorlaştırmakla kalmaz; aynı zamanda görüntü sınıflandırma ve segmentasyon gibi sonraki işleme adımlarının etkinliğini de ciddi şekilde düşürür (Pan ve diğ. 2022). Çok sayıda soruna sahip düşük ışıklı görüntüler için parlaklığı ve kontrastı artırmak amacıyla görüntü iyileştirme tekniklerinin kullanılması gereklidir. Böylece daha değerli bilgiler elde edilebilir ve bilgisayarla görme sistemlerindeki sonraki işlemler kolaylaştırılabilir (Lei ve Tian 2023). Düşük ışıkta görüntü iyileştirme, geniş bir uygulama yelpazesine sahiptir ve medya kalitesinin artırılmasından otonom sürüşte sahne algısına, akıllı gözetim sistemlerinden yüksek performanslı güvenlik çözümlerine kadar çeşitli alanlarda kullanılmaktadır (Kim 2022). Özellikle endüstriyel üretim kontrolü, askeri uygulamalar, su altı izleme, sürücü destek sistemleri gibi hayati öneme sahip alanlarda bu görüntülerin kalitesini artırmak, karar alma süreçlerinde önemli bir rol oynamaktadır (Anoop ve Deivanathan 2024).

Geleneksel yöntemlerle uydu görüntülerini analiz etmek genellikle ayrıntı ve netlik açısından yetersiz kalmaktadır ve bu da hızlı müdahale çabalarını engelleyebilmektedir. Bu bağlamda, gelişmiş görüntü işleme teknikleri, afet yönetiminde uydu görüntülerinin kullanılabilirliğini artırmak için potansiyel çözümler sunmaktadır. Görüntü işleme ve derin öğrenmedeki son gelişmeler, afet yönetiminde geniş veri kümelerinin otomatik ve doğru bir şekilde analiz edilmesine olanak sağlamaktadır (Putri ve diğ. 2024). Harnis ve diğ. (2023) uydu ve hava görüntü verilerini etkili bir şekilde gürültüden arındırmak için derin pekiştirmeli öğrenmeye dayalı bir yöntem uygulamışlardır. Sharma ve diğ (2021) uydu görüntülerinin iyileştirilmesi için geliştirilmiş bir teknik önererek, görsel algıyı artırırken detayları korumayı amaçlayan bir yaklaşım sunmuşlardır. Thriveni ve Ramashri (2013) uydu görüntülerinin algısal kalitesini iyileştirmek için ayrık dalgacık dönüşümü ve eşik ayrıştırma odaklı morfolojik filtre kullanarak bir uydu görüntü iyileştirme tekniği önermişlerdir. Naik ve Gharge (2016), Dual Tree Complex Wavelet dönüşümüne (DTCWT) ve onun döndürülmüş versiyonuna dayalı yeni bir uydu görüntü çözünürlüğü iyileştirme algoritması önermişlerdir. Chinaramanamma ve Anuradha (2024), çalışmalarında uydu görüntülerinin özelliklerini

iyileştirmeyi, bulanıklığı ve gürültüyü ortadan kaldırmayı, kontrastı artırmayı amaçlayan Yerel Olmayan Ortalamalar Filtresi'ni (NLM) Kontrast Sınırlı Adaptif Histogram Eşitleme (CLAHE) ile birleştiren yeni bir yaklaşım önermişlerdir. Trung ve diğ. (2023), küme iyileştirmeye dayalı uzaktan algılama görüntü iyileştirme (RSIECE) adı verilen karanlık uydu görüntülerinin kontrastının artırılması için yeni bir algoritma sunmuşlardır. Yulang ve diğ. (2021), uydu görüntülerinin ortalama parlaklığını ve kontrastını iyileştirebilen, görüntü ayrıntılarını geri kazandırabilen GAN tabanlı bir düşük ışık görüntü iyileştirme yöntemi önermişlerdir. Singh ve diğ. (2022) düşük ışıkta havadan çekilen görüntülerin görüntü iyileştirilmesinde farklı yerel ve küresel bağlam düzeylerinin daha iyi anlaşılması için çoklu çözünürlüklü dallar içeren RNet adlı yeni bir mimari önermişlerdir.

Düşük ışık koşullarında, sensörler şiddetli gürültüye sahip zayıf ışık sinyallerini yakalar ve bu da görüntülerin görsel kalitesinin kötü olmasıyla sonuçlanır. Bozulmuş görüntülerden yüksek kaliteli görüntüler elde etmek, genellikle düşük ışık görüntü iyileştirme (LLIE) süreçlerini gerektirir. Bu süreç, parlaklığı artırırken aynı anda gürültüyü ve renk sapmalarını minimize etmeyi hedeflemektedir (Li ve diğ. 2022). LLIE temelde gürültüyü azaltma, kenarları ve dokuları koruma ve doğal parlaklığı ve rengi yeniden üretme gibi görevleri kapsamaktadır (Matsui ve Ikehara 2023). Düşük ışık görüntü iyileştirmenin amacı, belirli bir görüntünün alta yatan içeriklerinde ciddi bozulmalar olmadan görünürlüğü iyileştirmektir (Kim 2022).

Literatürde, düşük ışıklı görüntüleri ve videoları iyileştirmek amacıyla farklı yöntemler önerilmektedir. Gri dönüşüm, histogram eşitleme, buğu giderme, Retinex, görüntü birleştirme, dalgacık dönüşümü ve makine öğrenimi olmak üzere yaygın olarak kullanılan yöntemler vardır (Anoop ve Deivanathan 2024). Literatürde birçok araştırmacı düşük ışık görüntü iyileştirme için çeşitli algoritmalar geliştirmiş olsa da hala çözüm bekleyen önemli sorunlar mevcuttur. Örneğin, bazı yöntemler aşırı karanlık bölgelerdeki içeriği yeterince ortaya çıkaramazken, bazıları aşırı iyileştirme riski taşımaktadır; diğerleri ise ayrıntılı bilgilerin kaybolmasına ve bulanıklaşmasına neden olabilmektedir (Pan ve diğ. 2022). Sharma ve diğ (2021) uydu görüntü iyileştirme teknikleriyle görsel algıyı artırmayı başarmış, ancak yöntemleri yapısal detayların korunmasında sınırlı kalmıştır. Benzer şekilde, Thriveni ve Ramashri (2013) tarafından önerilen dalgacık dönüşüm tabanlı iyileştirme yöntemleri, yüksek çözünürlüklü görüntülerde performans sergilese de düşük ışıklı görüntülerde renk doğruluğunu koruma açısından eksiklikler göstermiştir. Yulang ve diğ. (2021), GAN tabanlı bir yöntem sunarak görüntü detaylarını geri kazandırmayı başarmış, ancak bu yöntem, farklı ışık koşullarında tutarlılık sağlamada zorluk yaşamıştır. Son yıllarda, derin öğrenme yöntemleri özellikle görüntü işleme görevleri başta olmak üzere birçok alanda önemli ilerlemeler kaydetmiştir. Geleneksel yöntemlerden farklı olarak, derin öğrenme teknikleri görüntüdeki mekansal özellikleri yakalamaya daha fazla odaklanarak detayların daha iyi korunmasını sağlamakta ve gürültüye karşı daha dirençli bir yapı sunmaktadır. Düşük ışıklı görüntülerin iyileştirilmesi konusunda da derin öğrenme, dikkat çekici başarılar elde etmiştir. Geleneksel yöntemlerle karşılaştırıldığında, son yıllarda derin öğrenme tabanlı çözümler, düşük ışıklı görüntü kalitesini artırmada daha yüksek hassasiyet, sağlamlık ve verimlilik sunarak büyük ilgi görmüştür (Tian ve diğ. 2023).

Bu çalışmada öncelikle 6 Şubat 2023 tarihinde Türkiye’de meydana gelen depremlerin görüntüleri incelenmiştir. Bu depremlerin özellikle Kahramanmaraş ve Hatay ili civarındaki bölgelerde büyük yıkımlara yol açtığı bilinmektedir. Depremlerin meydana getirdiği zararı tespit etmek üzere ilk etapta alınan uydu görüntüleri, düşük ışık koşullarında elde edildiğinden bu durum görüntülerin iyileştirilmesine yönelik çabaları daha da önemli hale getirmiştir. Çünkü afet yönetiminde afete müdahale ve durum tespiti gibi görevler için kullanılacak uydu görüntüleri düşük ışık koşullarında alındığında, görüntülerde renk sapmaları, gürültü artışı ve detay kaybı gibi problemler görülebilmektedir. Bu çalışmanın amacı, düşük ışık koşullarında elde edilen uydu görüntülerini iyileştirerek afet yönetimine katkıda bulunmak ve bu hususta çeşitli yöntemleri karşılaştırarak araştırmacılara ve afet yöneticilerine düşük ışıklı görüntü iyileştirme süreci için bir perspektif sunmaktır. Bu doğrultuda çalışmada, İstanbul Teknik Üniversitesi Uydu Haberleşme ve Uzaktan Algılama Uygulama ve Araştırma Merkezi (İTÜ UHÜZAM) tarafından sağlanan ve Türkiye’de 6 Şubat 2023 tarihinde meydana gelen depremlerin akabinde Hatay iline ait düşük ışık koşullarında elde edilmiş uydu görüntüleri kullanılmıştır. Görüntülere Zero-DCE, CIDNet ve MIRNet gibi yeni ve yaygın olarak kullanılan LLIE algoritmaları uygulanmış ve performansları çeşitli metriklerle karşılaştırılmıştır.


Bu çalışmanın literatürdeki diğer çalışmalardan temel farkı, düşük ışıklı uydu görüntülerinde farklı derin öğrenme tabanlı yöntemlerin (Zero-DCE, CIDNet ve MIRNet) performanslarının kapsamlı bir karşılaştırmasını sunmasıdır. Özellikle, referans çalışmalarda sıkça göz ardı edilen farklı metriklerle değerlendirme ve uygulama senaryolarına uygunluk analizi bu çalışmada detaylı şekilde ele alınmıştır. Ayrıca, Türkiye’nin 6 Şubat 2023 depremleri sonrası toplanan gerçek uydu verilerinin kullanılması, bu çalışmayı literatürdeki diğer yöntemlerden ayıran önemli bir unsurdur.

Çalışmanın ikinci bölümünde, kullanılan görüntü iyileştirme yöntemleri, görüntü iyileştirme değerlendirme metrikleri ve veri kümesi ayrıntıları sunulmuştur. Üçüncü bölümde hem LOL veri seti hem de İTÜ UHÜZAM iyileştirme sonuçları sunulmuş olup, son bölümde ise çalışmanın sonucu verilmiştir.

2. YÖNTEM

Bu çalışmada Zero-DCE, CIDNet ve MIRNet modelleri iki farklı veri kümesinde çalıştırılmış ve sonuçları analiz edilmiştir. Birinci veri kümesi, İTÜ UHÜZAM tarafından sağlanan düşük ışık koşullarında elde edilmiş uydu görüntülerinden oluşmaktadır. İTÜ UHÜZAM veri setinde Hatay iline ait düşük ışık koşullarında elde edilmiş uydu görüntülerinden oluşan 20 adet tif belgesi kullanılmıştır. Bu görüntülerin genişlikleri 4751-12288 ve yükseklikleri 4461-14336 piksel aralıklarında değişmektedir. Öncelikle büyük boyutlu bu görüntüler 1024x1024 boyutlarında kesilmiş, bunlar arasından yapıların olmadığı veya çok az olduğu görüntüler ayıklanmış ve yapıların yoğunlukta olduğu görüntüler seçilmiştir. Sonuçta 748 görüntüden oluşan bir veri seti elde edilmiştir. Bu veri seti ilk kez bu çalışmada kullanılmıştır. Şekil 1’de veri setimizdeki örnek görüntüler görülmektedir. İkinci veri kümesi ise hem aydınlık hem de düşük ışıklı görüntüler içeren ve düşük ışık görüntü iyileştirme çalışmalarında sıklıkla kullanılan LOL veri setidir (Wei ve diğ. 2018).

Şekil 1’deki görüntüler, popüler düşük ışık görüntü iyileştirme yöntemlerinden Zero-DCE, CIDNet ve MIRNet yöntemleri uygulanarak iyileştirilmiş ve karşılaştırmalı bir analiz yapılmıştır. Her bir yöntemin performansı Tepe Sinyal-Gürültü Oranı (PSNR), Yapısal Benzerlik Endeksi (SSIM) ve Öğrenilmiş Algısal Görüntü Yama Benzerliği (LPIPS) metrikleri kullanılarak değerlendirilmiştir.



Şekil 1: Veri setinden örnek bazı görüntüler
Figure 2: Sample images from the dataset

Görüntülerin iyileştirilmesiyle felaketten etkilenen bölgelerdeki hasar tespiti, ne kadar yardım ve müdahaleye ihtiyaç duyulduğu gibi kritik bilgilerin daha net bir şekilde belirlenmesi mümkün olmaktadır. Böylelikle, afet yönetiminin planlanması daha etkin ve hızlı bir şekilde gerçekleştirilebilmektedir. Ayrıca farklı yöntemlerin uygulanması ve sonuçların değerlendirilmesiyle afet yöneticilerine bir yol haritası çizilmektedir. Şekil 2’de uydu görüntü iyileştirme sürecini ve afet yönetimi ile iyileştirme operasyonlarına katkılarını genel hatlarıyla özetleyen bir şema sunulmuştur. Burada görüntü iyileştirme, uydu verilerinin etkin bir şekilde işlenebilmesi için önemli bir adımdır ve

afet bölgelerindeki kritik bilgilerin elde edilmesine yardımcı olmaktadır. Şemada, uydu görüntülerinin toplanmasıyla başlayan süreç, çeşitli iyileştirme tekniklerinin uygulanması ile devam etmekte ve elde edilen iyileştirilmiş görüntülerin, afet sonrası müdahalelerde nasıl kullanılabileceğiyle son bulmaktadır. Bu çalışmada ana odak, görüntü iyileştirme teknikleri üzerine olup, bu aşamada farklı yöntemlerin uygulanması ayrıntılı bir şekilde gösterilmektedir. Bu yöntemler, görüntülerin analiz için optimize edilmesini sağlamakta ve sonrasında kullanılacak karar destek sistemlerine daha doğru ve net verilerin elde edilmesini sağlamaktadır.




Şekil 2: Uydu görüntü iyileştirme süreci ve afet yönetimindeki rolü
Figure 2: Satellite image enhancement process and its role in disaster management

2.1) Zero-DCE Yöntemi

Zero-Reference Deep Curve Estimation (Zero-DCE), düşük ışıklı görüntülerin iyileştirilmesi için geliştirilen yenilikçi bir derin öğrenme yöntemidir. Bu yöntem, görüntü tabanlı eğriler aracılığıyla dinamik aralığı ayarlayarak görüntülerin parlaklığını artırmayı amaçlamaktadır. Zero-DCE'nin en dikkat çekici özelliği, eğitim sırasında referans görüntüye ihtiyaç duymamasıdır. Bu yöntem, eşleştirilmiş veya eşleştirilmemiş veri setlerine dayanmaksızın, yalnızca hedef görüntünün kendisiyle çalışarak eğitimin gerçekleştirilmesini sağlamaktadır. Yöntem, çeşitli kayıplar kullanarak düşük ışıklı

görüntüleri iyileştirir ve bu süreçte parlaklık, renk tutarlılığı ve ayrıntıları korumayı hedeflemektedir (Guo ve diğ. 2020).

Zero-DCE, düşük ışıklı görüntülerdeki parlaklık sorunlarını gidermek için Light-Enhancement Curve (LE-curve) ve DCE-Net bileşenlerini kullanmaktadır. DCE-Net, bir giriş görüntüsüne en uygun ışıklandırma eğrilerini belirleyerek görüntüyü otomatik olarak aydınlatmaktadır. Bu süreçte, her bir RGB kanalındaki pikseller, LE-eğrileri aracılığıyla iteratif olarak dönüştürülerek son aydınlatılmış görüntü elde edilmektedir. Model bileşenlerinin şeması Şekil 3'te verilmiştir.



Şekil 3: Zero-DCE modeli
Figure 3: Zero-DCE Model

LE-eğrileri, fotoğraf düzenleme yazılımlarında yaygın olarak kullanılan eğri ayarlama tekniklerinden ilham alınarak, düşük ışıklı bir görüntüyü aydınlatılmış bir hale getirmek üzere tasarlanmıştır. Denklem 1'de eğri fonksiyonu verilmiştir.

$$LE(I(x); \alpha) = I(x) + \alpha I(x)(1 - I(x)) \quad (1)$$

Denklem 1'de x piksel koordinatlarını, $LE(I(x); \alpha)$ geliştirilmiş versiyonu ve α ise eğri parametresini ifade eder. Bu parametre, LE-eğrisinin büyüklüğünü ayarlayarak ışık seviyesini kontrol etmektedir. Her bir RGB kanalı ayrı ayrı işlenir ve böylece görüntünün doğal rengi korunur. Her pikselin kendine özgü bir α parametresi ile işlenmesi için pixel-bazında bir parametre

haritası kullanılır. Bu harita, her piksele özgü bir A değeri tanımlayarak farklı parlaklık seviyelerine uygun dönüşüm sağlar.

DCE-Net, düşük ışıklı bir giriş görüntüsüne ait en uygun eğri parametre haritalarını öğrenmek için tasarlanmış bir Derin Eğri Tahmin Ağıdır. Yedi katmanlı bir evrişimli ağ olup, her bir katmanda 3x3 boyutunda 32 konvolüsyon çekirdeği bulunmaktadır. Son katman, Tanh aktivasyon fonksiyonuyla çalışır ve her bir RGB kanalı için 8 iterasyonluk eğri parametre haritalarını üretmektedir. Bu yapı toplamda 79.416 parametre ile oldukça hafif olup, sınırlı hesaplama kaynakları olan cihazlarda kullanılabilir (Guo ve diğ. 2020).


2.2) CIDNet Yöntemi

CIDNet, düşük ışık koşullarında çekilmiş görüntüleri iyileştirmek amacıyla tasarlanmış bir derin öğrenme modelidir. Model, yaygın olarak kullanılan sRGB veya HSV yerine, yatay-dikey yoğunluk (Horizontal/Vertical-Intensity, HVI) adı verilen bir renk uzayı kullanmaktadır. HVI, RGB renk kanallarındaki parlaklık ve renk bileşenlerini ayrıştırarak görüntü iyileştirme sürecini daha stabil hale getirmektedir. HVI renk uzayında, üç eğitilebilir parametre ve bir eğitilebilir fonksiyon kullanılarak, modelin farklı ışıklandırma koşullarına uyum sağlaması hedeflenmiştir (Yan ve diğ. 2024).

CIDNet, iki dallı bir ağ mimarisine dayanmaktadır. Bu dallar, parlaklık ve renk bilgilerini ayrı ayrı işleyerek, HVI uzayına dönüştürülen görüntüden elde edilen parlaklık ve renk haritaları ile beslenmektedir. Parlaklık haritası, sahnedeki ışık yoğunluğunu temsil ederken, renk haritası sahnedeki renk ve yapısal bilgileri içermektedir. Bu yapı, düşük ışıklı ortamlarda oluşan gürültü ve renk sapmalarını azaltmayı hedeflemektedir. Modelin önemli bileşenlerinden biri olan Lighten Cross-Attention (LCA) modülü, parlaklık ve renk dalları arasındaki

etkileşimi güçlendirmektedir. LCA modülü, iki dal arasında bilgi alışverişini sağlayarak, her iki dalın da uyumlu ve tamamlayıcı özellikler öğrenmesine katkıda bulunmaktadır. Bu modül, parlaklık bilgisini artırırken renk doğruluğunu korumakta ve gürültüyü azaltmaktadır.

CIDNet'in genel çerçevesi HVI dönüşümü, geliştirme ağı ve ters HVI dönüşümü olmak üzere üç aşamalı bir süreç izlemektedir. CIDNet'in çerçevesinin genel şeması Şekil 4'te verilmiştir. İlk aşamada, sRGB görüntüsü HVI uzayına dönüştürülerek yoğunluk ve HV renk haritalarına ayrılmaktadır. Yoğunluk haritası ve HV renk haritası, düşük ışıklı görüntü iyileştirme sürecinde modelin giriş verilerini oluşturmaktadır. Bu haritalar, Lighten Cross-Attention (LCA) modülüyle birlikte UNet tabanlı bir geliştirme ağına beslenmektedir. Sürecin sonunda, rafine edilmiş yoğunluk ve HV haritaları kullanılarak görüntü, sRGB uzayına geri dönüştürülmektedir (Yan ve diğ. 2024). CIDNet, düşük ışık koşullarında dahi hem parlaklık hem de renk doğruluğunu koruyarak yüksek kaliteli görüntülerin üretilmesine olanak tanımaktadır. Modelin HVI renk uzayını kullanması ve çift dallı yapısı, düşük ışıklı görüntü iyileştirme alanında önemli bir yenilik olarak öne çıkmaktadır.




Şekil 4: CIDNet modeli şeması

Figure 4: CIDNet model schema

2.3) MIRNet Yöntemi

MIRNet, görüntü iyileştirme ve restorasyon sürecine odaklanmaktadır. Bu yöntemin temelini çok ölçekli artık bloklar oluşturmaktadır ve MIRNet'in çok katmanlı yapısında, çok çözünürlüklü paralel evrişim akışları kullanılarak inceden kaba seviyeye semantik olarak zengin ve kabadan ince seviyeye mekansal olarak hassas özellikler elde edilmektedir. Ayrıca,

çok çözünürlüklü akışlar arasında bilgi paylaşımı yapılmakta, çok akışlı özellikler bir araya getirilmekte ve kanallardaki ve mekansal boyutlardaki bağlamsal bilgiyi yakalayan ikili dikkat mekanizmaları kullanılmaktadır. Çözünürlük değiştirme modülleri ise veri akışının aşağı ve yukarı örneklenmesi işlemlerini gerçekleştirmektedir. MIRNet'in şema görünümü Şekil 5'te verilmiştir (Zamir ve diğ. 2020).



Şekil 5: MIRNet modeli şeması

Figure 5: MIRNet model schema

MIRNet'e giriş olarak verilen bir görüntü, düşük seviyeli özelliklerin çıkarılması amacıyla bir evrişim katmanından geçirilmekte ve bu işlem sonucunda özellik haritaları elde edilmektedir. Bu özellik haritaları, derin özelliklerin çıkarılması için birden fazla yinelemeli artık gruba (RRG) aktarılmaktadır. Her bir RRG, çok ölçekli artık bloklardan oluşmaktadır. Sürecin sonunda, derin özellik haritaları üzerinde bir evrişim işlemi uygulanarak bir artık görüntü oluşturulmaktadır. Bu artık görüntü, giriş görüntüsüne eklenerek iyileştirilmiş bir sonuç elde edilmektedir. Ağın eğitiminde, iyileştirilmiş görüntü ile gerçek görüntü arasındaki farkı minimize eden Denklem 2'de belirtilen Charbonnier kaybı kullanılmaktadır. Denklem 2'de I^* gerçek görüntüyü, $\hat{I}$ ise iyileştirilmiş çıktıyı temsil etmektedir. Bu fonksiyonda kullanılan ϵ değeri tüm deneylerde 10-3 olarak belirlenmiştir.

$$L(\hat{I}, I^*) = \sqrt{\|\hat{I} - I^*\|^2 + \epsilon^2} \quad (2)$$

Çok ölçekli artık blok (MRB), aynı katmanda çok ölçekli mekânsal bilgiyi birleştirme kapasitesine sahiptir. Bu blok, yüksek çözünürlüklü temsilleri korurken, düşük çözünürlüklerden gelen bağlamsal bilgileri de işleyebilmektedir. MRB, paralel olarak bağlanmış üç tam evrişimli akıştan oluşmaktadır. Bu akışlar arasında bilgi paylaşımı sağlanarak, düşük çözünürlüklü özelliklerin yüksek çözünürlüklü özelliklerle bir araya getirilmesi hedeflenmektedir. MRB'nin temel bileşenlerinden biri olan seçici çekirdek özellik birleştirme (SKFF) modülü, görsel korteksteki uyarılara göre alıcı alan boyutlarını ayarlayabilen nöronların işlevlerinden esinlenerek geliştirilmiştir. SKFF modülü Birleştirme ve Seçme gibi iki ana işlemi gerçekleştirmektedir. Birleştirme operatörü, çoklu çözünürlük akışlarından gelen bilgileri birleştirerek küresel bir özellik tanımlayıcı oluşturmaktadır. Seçme operatörü ise bu tanımlayıcıları kullanarak, farklı çözünürlüklerdeki özellik haritalarını yeniden ölçeklendirmekte ve optimize etmektedir. Ayrıca, çift dikkat birimi (DAU), MRB içerisinde bilgiyi hem kanal hem de mekânsal boyutlarda paylaşarak özellik haritalarını yeniden ölçeklendirmektedir. DAU, dikkat mekanizmalarını kullanarak önemli özellikleri vurgularken gereksiz olanları bastırmayı hedeflemektedir. DAU kanal dikkati ve mekânsal dikkat olmak üzere iki ana bileşenden oluşmaktadır. Kanal dikkati, kanal ilişkilerini değerlendirerek bir sıkıştırma ve genişletme işlemi gerçekleştirmekte ve özelliklerin kanal bazında önemini belirlemektedir. Mekânsal dikkat ise mekânsal bağımlılıkları inceleyerek, görüntüdeki önemli bölgeleri vurgulamak için bir dikkat haritası oluşturmaktadır. DAU, bu mekanizmalar sayesinde, yalnızca bilgilendirici ve değerli özelliklerin işlenmesini sağlayarak modelin genel performansını artırmaktadır (Zamir ve diğ. 2020).

2.4) Karanlık Görüntü İyileştirme Metrikleri

Görüntü işleme uygulamalarında yapılan işlemler, genellikle görüntü kalitesinde veya bilgi içeriğinde önemli kayıplara neden olabilmektedir. Bu kayıpları değerlendirmek için kullanılan yöntemler, iki ana kategoriye ayrılmaktadır: subjektif ve objektif değerlendirme yöntemleri (Kreis 2004, Avcibas ve diğ. 2002). Subjektif yöntemler, insan yargısına dayanır ve

genellikle belirli bir sayısal kriter olmaksızın değerlendirme yapılır (Farrell 1999). Buna karşın, objektif yöntemler, referans görüntüye veya istatistiksel parametrelerle tanımlanmış ön bilgilere dayalı olarak sayısal karşılaştırmalar yapmaya olanak sağlar (Cadik ve Slavik 2004, Hore ve Ziou 2010). Bu çalışmada, görüntü iyileştirme işlemleriyle elde edilen görüntülerin kalite değerlendirmeleri için üç yaygın objektif metrik olan PSNR, SSIM ve LPIPS kullanılmıştır.

2.4.1) PSNR (Peak Signal-to-Noise Ratio)

Bu metrik bir görüntünün kalite değerlendirmesi için kullanılan yaygın bir objektif ölçüm yöntemidir. Metrik, genellikle referans görüntü (f) ile test görüntüsü (g) arasındaki farkı ölçmek için kullanılır ve Denklem 3'teki gibi tanımlanır (Tian ve diğ. 2023).

$$PSNR(f, g) = 10 \log_{10} \left(\frac{255^2}{MSE(f, g)} \right) \quad (3)$$

Burada $MSE(f, g)$ (Mean Squared Error), referans ve test görüntüleri arasındaki ortalama kare hata farkıdır ve Denklem 4'teki gibi ifade edilmektedir.

$$MSE(f, g) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f_{ij} - g_{ij})^2 \quad (4)$$

PSNR değeri, MSE azaldıkça yükselmektedir. Başka bir deyişle, görüntüler arasındaki fark ne kadar küçük olursa, PSNR değeri o kadar yüksek olmaktadır. Bu durum, yeniden oluşturulan görüntünün orijinaline daha yakın olduğunu ve daha yüksek bir kaliteye sahip olduğunu göstermektedir. Yüksek bir PSNR değeri, görüntü kalitesinin daha yüksek olduğunu göstermektedir. Küçük PSNR değerleri ise görüntüler arasındaki farkın büyük olduğunu ve dolayısıyla düşük kaliteyi ifade etmektedir. PSNR özellikle Gaussian gürültü gibi eklenti gürültülerinin etkisini ölçmede oldukça başarılı bir metriktir. Ancak, bazı durumlarda PSNR'nin yapısal içerikleri ayırt etme konusunda yetersiz kaldığı da gözlemlenmiştir. PSNR, gürültü gibi basit bozulmaların ölçümünde etkili bir yöntem sunarken, yapısal farklılıkları değerlendirme konusunda belirli sınırlamalara sahiptir (Kreis 2004).

2.4.2) SSIM (Structural Similarity Index)

Bu metrik görüntü kalitesi değerlendirme metrikleri arasında, insan görsel algısına en yakın sonuçları sağlayan, hata duyarlılığı yaklaşımının ötesine geçen modern bir yaklaşımdır. Geleneksel görüntü kalite değerlendirme yöntemleri, bozulmuş görüntü ile referans görüntü arasındaki piksel farklarını hata miktarına göre ölçerken, SSIM, görüntünün yapısal bütünlüğünü temel alarak kaliteyi değerlendirmeyi amaçlar. İnsan görsel sistemi (HVS) üzerine yapılan çalışmalar, insanların görüntüdeki yapısal bilgiyi algılamaya daha yatkın olduğunu göstermektedir. Bu nedenle SSIM, iki görüntü arasındaki yapısal benzerliği analiz ederek kaliteyi ölçmektedir (Wang ve diğ. 2004).

SSIM, görüntülerdeki yerel yapısal bilgiyi karşılaştırmak için parlaklık, kontrast ve yapı temel bileşeni kullanmaktadır. Bu bileşenler, görüntüdeki yerel piksellerin istatistiksel özelliklerini inceleyerek her birinde yapısal uyum düzeyini hesaplamaktadır. SSIM metriği, parlaklık, kontrast ve yapı karşılaştırmalarını birleştirerek genel bir benzerlik skoru sağlamaktadır. Bu üç bileşen, Denklem 5'teki SSIM formülünde bir araya getirilmiştir. Denklem 5'e göre iki görüntü arasındaki benzerliği 0 ile 1 arasında bir değerle ifade edilmektedir; 1, tamamen benzer 2 görüntü için en yüksek benzerlik değeridir (Wang ve diğ. 2004).

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

SSIM, görüntüdeki yerel piksellerin istatistiksel özelliklerini analiz ederek yapısal uyumu ölçmektedir. Parlaklık benzerliğini yerel ortalama parlaklıklarla, kontrast benzerliğini ise standart sapmalarla değerlendirir. Yapısal uyum, normlaştırılmış yoğunluk desenlerinin iç çarpımıyla hesaplanmaktadır.

2.4.3) LPIPS (Learned Perceptual Image Patch Similarity)

Geleneksel görüntü kalite değerlendirme metrikleri, örneğin PSNR veya SSIM, görüntülerin piksel düzeyindeki farklarını değerlendirerek benzerlik ölçümü yapmaktadır. Ancak bu tür metrikler, insan görsel algısının karmaşıklığını tam olarak yakalayamaz ve çoğunlukla insan algısıyla uyumlu sonuçlar verememektedir. LPIPS bu eksikliği gidermek için derin öğrenme temelli bir yaklaşım sunar ve görüntüler arasındaki algısal benzerliği, insan algısıyla uyumlu olacak şekilde ölçmektedir (Zhang ve diğ. 2018).

LPIPS, VGG, AlexNet ve SqueezeNet gibi derin ağların ara katmanlarından elde edilen özellikleri kullanarak görüntüler arasındaki algısal farkları değerlendirmektedir. Bu yöntem, özellikle bir görüntünün sınıflandırma veya nesne tanıma gibi yüksek seviyeli bir görev için eğitilmesine dayanmaktadır. LPIPS, sadece eğitim sinyaliyle eğitilmiş ağların dahi insan algısıyla uyumlu benzerlik ölçümleri üretebileceğini göstermektedir.

LPIPS referans görüntü ile bozulmuş görüntü arasındaki derin özellik farklarını hesaplamaktadır. Bu işlem sırasında, her katmandan elde edilen özellikler normalize edilip kanal boyutunda ölçeklendirilmekte ve ardından görüntüler

arasındaki algısal benzerlik derecesini ifade eden bir mesafe hesaplanmaktadır. Bu hesaplama, Denklem 6'da verilen formül aracılığıyla gerçekleştirilmektedir.


$$d(x, x_0) = \sum_l \frac{1}{H_l W_l} \sum_{h,w} \|w_l \odot (\hat{y}_{hw}^l - \hat{y}_{0hw}^l)\|_2^2 \quad (6)$$

Denklem 6'da $d(x, x_0)$, iki görüntü arasındaki LPIPS algısal mesafesini ifade etmektedir. $\hat{y}_{hw}^l$, $\hat{y}_{0hw}^l$ görüntülerin l'ninci katmandaki özellik çıkışı temsil etmektedir. H_l ve W_l katmanın boyutlarını gösterirken, w_l , her katmanın özellik kanalına uygulanan ağırlık vektörünü göstermektedir (Zhang ve diğ. 2018).


3. KARANLIK GÖRÜNTÜ İYİLEŞTİRME SONUÇLARI

Bu çalışmada, Zero-DCE, CIDNet ve MIRNet modellerinin performansları, uydu görüntülerinden oluşan veri seti üzerinde PSNR, SSIM ve LPIPS gibi popüler metrikler kullanılarak değerlendirilmiştir. Ancak İTÜ UHUZAM veri setinde görüntülerin sadece düşük ışıklı halleri bulunmaktadır. PSNR, SSIM ve LPIPS metrikleri için görüntülerin hem düşük hem de iyileştirilmiş yüksek ışıklı halleri gereklidir. Zero-DCE, CIDNet ve MIRNet modellerinin performansları test etmek için hem düşük ışıklı hem de yüksek ışıklı görüntüleri içeren ve literatürde sıklıkla kullanılan LOL veri seti kullanılmıştır (Wei ve diğ. 2018). Tüm modeller LOL veri setinde 100 epok boyunca eğitilmiş ve elde edilen ağırlıklarla doğrulama görüntülerinden iyileştirilmiş çıktılar oluşturulmuştur. Eğitim işlemleri için ilgili modellerin Github sayfalarında paylaşılan kodlar kullanılmıştır (HVI-CIDNet GitHub 2024, MIRNet GitHub 2024, Zero-DCE GitHub 2024). Şekil 6'da modellerin LOL veri setindeki eğitim süreci hata eğitileri sunulmuştur. Her iki veri kümesinde modellerin hiper parametreleri olarak öğrenme katsayısı (learning rate) 0.0001, paket büyüklüğü (batch size) 8 ve iterasyon sayısı (epoch) 100 olarak belirlenmiştir. Modellerin eğitimi süresince öğrenme katsayısı dinamik olarak düşürülmüştür. Eğitim aşamasında modelin doğrulama hatası beş iterasyon boyunca azalmazsa, öğrenme oranı yarıya düşürülecek şekilde ayarlanmıştır.

LOL veri setindeki ground truth (gerçek veri) ile modellerden alınan iyileştirilmiş görüntüler ayrı ayrı karşılaştırılmıştır. Şekil 7'de LOL veri setindeki düşük ve yüksek ışıklı görüntüler, modellere ait iyileştirilmiş görüntüler ve her bir görüntü için hesaplanan metrikler verilmiştir.



Şekil 6: Modellerin LOL veri setinde eğitim süreci hata grafikleri; a) Zero-DCE hata eğrisi, b) CIDNet hata eğrisi, c) MIRNet hata eğrisi
Figure 6: Training loss of models on the LOL dataset: a) Zero-DCE loss, b) CIDNet loss, c) MIRNet loss




Şekil 7: Modellerin LOL veri setindeki sonuçlarının görselleri
Figure 7: Visual results of the models on the LOL dataset

3.1) LOL veri seti sonuçları

LOL veri setindeki doğrulama görüntüleri için görüntülerin yüksek ışıklı gerçek halleri ile modellere ait iyileştirilmiş


görüntü çıktıların kıyaslanmasıyla hesaplanan metriklerin ortalama değerleri Şekil 8'de sunulmuştur.



Şekil 8: Model çıktıların LOL veri seti gerçek doğru görüntüleri ile karşılaştırması
Figure 8: Comparison of model outputs with ground truth images from the LOL dataset

Şekil 8'deki sonuçlara göre Zero-DCE, özellikle parlaklık artırmada etkili olurken metrikler açısından CIDNet ve MIRNet'in gerisinde kalmıştır. CIDNet ve MIRNet ise hem görsel algı açısından hem de metrikler açısından birbirlerine

yakın sonuçlar elde etmiştir. Daha sonra aynı karşılaştırma, LOL veri seti doğrulama görüntülerinin orijinal, yani düşük ışıklı halleriyle model çıktıları arasında yapılmış ve metrik sonuçları Şekil 9'da sunulmuştur.



Şekil 9: Model çıktıların LOL veri seti orijinal görüntüleri ile karşılaştırması
Figure 9: Comparison of model outputs with original images from the LOL dataset

Bu iki farklı kıyaslama yöntemi, metrik değerlerinin her iki şekilde de tutarlılığı konusunda önemli bilgiler sunmuş; yüksek ve düşük ışıklı görüntülerle elde edilen sonuçların orantılı olması, uydu görüntülerinde metriklerin kullanımının güvenilirliğini sağlamıştır.

3.2) İTÜ UHUZAM veri seti sonuçları

CIDNet ve MIRNet eğitim için hem düşük ışıklı hem de yüksek ışıklı görüntülere ihtiyaç duyduğundan LOL veri setiyle elde edilen ağırlıklar, uydu görüntülerini iyileştirmek için de kullanılmıştır. Zero-DCE ise eğitim için referans görüntülere ihtiyaç duymadığı için veri setimizdeki görüntülerle eğitim işlemi gerçekleştirilmiştir. Eğitim işlemine ait grafik Şekil 10'da verilmiştir.



Şekil 10: Zero-DCE modelinin İTÜ UHUZAM veri seti eğitim süreci hata eğrisi

Figure 10: Training loss of the Zero-DCE model on the İTÜ UHUZAM dataset

Daha sora elde edilen ağırlıklarla uydu görüntüleri iyileştirilmiş ve her model için orijinal görüntülerle iyileştirilmiş görüntüler arasında PSNR, SSIM ve LPIPS metrikleri hesaplanmıştır.

Şekil 11'de örnek görüntüler, iyileştirilmiş halleri ve her bir görüntüye ait metrik sonuçları sunulmuştur.




Şekil 11: İTÜ UHUZAM veri seti örnek görüntülerin karşılaştırılması

Figure 11: Comparison of sample images from the İTÜ UHUZAM dataset

Zero-DCE yöntemi ile iyileştirilen görüntüler daha parlak ve görsel olarak çekici görünmektedir. Bu yöntemin parlaklığı artırma konusundaki başarısı, görüntülerin canlı ve net bir izlenim yaratmasına yardımcı olmuştur. Ancak, görüntü kalitelerinin nesnel olarak değerlendirilmesi de gerektiğinden

bu alanda kullanılan popüler üç metrik ile sonuçlar hesaplanmış ve tüm görüntülerden elde edilen ortalama değerler Şekil 12'de sunulmuştur. Sonuçlarda Zero-DCE'nin parlak görüntüler üretmesine rağmen diğer yöntemlerle kıyaslandığında bazı zayıf yönleri olduğu görülmektedir.



Şekil 12: Görüntü iyileştirme yöntemlerinin İTÜ UHUZAM veri setindeki sonuçları
Figure 12: Results of image enhancement methods on the İTÜ UHUZAM dataset

Görüntülerden elde edilen ortalama değerler üç düşük ışık iyileştirme yönteminin farklı alanlarda üstünlük sağladığını göstermektedir. CIDNet, ortalama PSNR, SSIM ve LPIPS değerlerinde en yüksek performansı sergileyerek, özellikle yapısal doğruluğu ve detayların korunmasını ön planda tutan bir yaklaşım olduğu görülmektedir. Bu yöntem, görüntüdeki ayrıntıları ve yapısal benzerliği koruyarak, analiz ve sınıflandırma gibi sonraki görsel işleme görevlerinde daha iyi sonuçlar verebilir. Bu nedenle, yapısal doğruluğun ve detayların korunmasının kritik olduğu durumlar için CIDNet önerilen yöntem olarak öne çıkmaktadır.

MIRNet, görsel değerlendirmelerde renk doğruluğu ve parlaklık ayarı konusunda başarılı bir model olarak değerlendirilmektedir. Renk tonlarını iyileştirme ve parlaklık seviyesini düzenlemedeki üstün başarısı, görsel estetiğin ön planda olduğu uygulamalar için büyük bir avantaj sağlar. Özellikle görsel algılama, insan odaklı arayüz uygulamaları ve görsel tabanlı etkileşim gerektiren sistemlerde, kullanıcı deneyimini iyileştirebilir. Ayrıca yine analiz ve sınıflandırma görevlerinde de kullanılabilecek güçlü bir modeldir.

Zero-DCE, PSNR, SSIM ve LPIPS metriklerinde en düşük sonuçları elde etmesine rağmen, parlaklık iyileştirmede başarılı olmuştur. Bu yöntem, hızlı bir iyileştirme çözümü arayan,

ancak detay kayıplarına ve yapısal bozulmalara daha toleranslı olan uygulamalar için uygun olabilir. Özellikle parlaklık arttırmanın ön planda olduğu, ancak yapısal doğruluğun daha az kritik olduğu durumlarda Zero-DCE tercih edilebilir.

Bu sonuçlar, görsel iyileştirme çalışmalarında hem sayısal metriklerin hem de görsel değerlendirmelerin birlikte ele alınmasının önemini vurgulamaktadır. Sayısal metrikler, modelin objektif performansını değerlendirirken, görsel değerlendirmeler de algısal kaliteyi ortaya koyarak, nihai kullanım amacıyla daha uyumlu çözümler geliştirilmesine olanak sağlar. Genel olarak, CIDNet, detay ve yapısal doğruluk isteyen uygulamalar için, MIRNet ise renk ve görsel estetik odaklı iyileştirmeler için daha uygunken, Zero-DCE parlaklık artışı isteyen hızlı çözümler için tercih edilebilir. Bu üç yöntem, düşük ışıklı görüntülerin iyileştirilmesi alanında farklı gereksinimlere yönelik farklı çözümler sunmakta ve düşük ışık görüntü iyileştirme alanına önemli katkılar sağlamaktadır.

4. SONUÇ

Düşük ışık koşullarında elde edilen uydu görüntülerinin iyileştirilmesi, afet yönetimi ve kurtarma operasyonlarının etkinliği açısından büyük önem taşımaktadır. Bu çalışmada Türkiye'de meydana gelen depremler sonrasında toplanan düşük ışıklı uydu görüntülerini iyileştirmek amacıyla

Zero-DCE, CIDNet ve MIRNet gibi derin öğrenme tabanlı yöntemlerin performanslarını karşılaştırmalı olarak değerlendirmiştir. Modellerin performansları PSNR, SSIM ve LPIPS gibi popüler metriklerle analiz edilmiş ve görsel değerlendirmelerle desteklenmiştir.

Çalışmanın sonucunda her modelin farklı alanlarda üstünlük sağladığını göstermiştir. CIDNet, yapısal doğruluk ve detayların korunmasında en yüksek performansı sergilemiş, bu yönüyle analiz ve sınıflandırma gibi görsel işleme görevleri için güçlü bir aday olarak öne çıkmıştır. Örneğin, deprem sonrası hasar tespitinde, binaların yapısal bütünlüğünü ve yol ağlarının tespitini gerektiren senaryolarda CIDNet'in kullanımı önerilmektedir. MIRNet, renk doğruluğu ve parlaklık iyileştirme konularında üstün bir başarı göstermiş, görsel estetiğin ön planda olduğu uygulamalar için ideal bir çözüm sunmuştur. Özellikle afete yönelik medya raporlamaları veya görsel haritalama projelerinde MIRNet'in tercih edilmesi uygundur. Zero-DCE ise parlaklık artırma konusunda etkili bir yöntem olarak dikkat çekmiş, ancak detay kaybı ve yapısal

bozulmalar nedeniyle sınırlı uygulama alanlarına sahip olduğu gözlemlenmiştir. Örneğin, düşük hesaplama kaynaklarına sahip mobil uygulamalar veya hızlı bir şekilde bölgesel ön inceleme gerektiren durumlarda Zero-DCE faydalı olabilir. Bu bulgular, düşük ışık görüntü iyileştirme çalışmalarında, uygulamanın gereksinimlerine göre farklı yöntemlerin seçilmesinin önemini vurgulamaktadır. Bu çalışmanın sonucunda detay ve yapısal doğruluğun kritik olduğu durumlar için CIDNet, görsel estetiğin ön planda olduğu alanlar için MIRNet, hızlı bir parlaklık iyileştirme gerektiren senaryolar için ise Zero-DCE önerilmektedir.

Sonuç olarak bu çalışma, afet yönetimi gibi zorlu uygulamalarda düşük ışıklı uydu görüntülerinin iyileştirilmesi için derin öğrenme tabanlı yöntemlerin potansiyelini ortaya koymakta ve bu alandaki araştırmalar için değerli bir perspektif sunmaktadır. Gelecekte, bu modellerin birleştirilmesi veya hibrit yaklaşımların geliştirilmesi, daha kapsamlı ve verimli çözümler sunabilir. Bu bağlamda, elde edilen sonuçlar hem araştırmacılar hem de uygulayıcılar için yol gösterici niteliktedir.

TEŞEKKÜR

Bu çalışmada kullanılan 6 Şubat 2023 depremine ait uydu görüntüleri İstanbul Teknik Üniversitesi Uydu Haberleşme ve Uzaktan Algılama Uygulama Araştırma Merkezi'nden temin edilmiştir. Veri kümesinin araştırma için paylaştıklarından İstanbul Teknik Üniversitesi Uydu Haberleşme ve Uzaktan Algılama Uygulama Araştırma Merkezi'ne teşekkür ederiz. Ayrıca bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 123E669 numaralı proje kapsamında desteklenmiştir. TÜBİTAK'a desteklerinden dolayı teşekkür ederiz.

KAYNAKLAR

Anoop P.P., Deivanathan R., 2024. Advancements in low light image enhancement techniques and recent applications, *Journal of Visual Communication and Image Representation*, 104223.

Avcibas I.S., Sankur B.L., Sayood K., 2002. Statistical evaluation of image quality measures, *Journal of Electronic Imaging*, 11(2), 206-223.

Cadik M., Slavik P., 2004. Evaluation of two principal approaches to objective image quality assessment, Eighth International Conference on Information Visualisation, 16-16 July 2004, London, UK, Erişim adresi: <https://doi.org/10.1109/IV.2004.1320193>.

Chinaramanamma D., Anuradha B., 2024. Image enhancement of satellite images using contrast limited adaptive histogram equalization and NLM, *International Journal of Scientific Research in Science and Technology*, 11(2), 177-181.

Farrell J.E., 1999. Image quality evaluation, *Colour imaging: vision and technology*, 1(1), 285-313.

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, *IEEE/CVF conference on computer vision and pattern recognition*, 13-19 June 2020, Seattle, WA, USA, Erişim adresi: <https://doi.org/10.1109/CVPR42600.2020.00185>.

- Hanis S., Narayanan S.A., Viswanath P.A., Bhooshan V., 2023. Satellite and Aerial Image Restoration Using Deep Reinforcement Learning, *Fluctuation and Noise Letters*, 22(05), 2350039.
- Hore A., Ziou D., 2010. Image quality metrics: PSNR vs. SSIM, 20th international conference on pattern recognition, 23-26 August 2010, Istanbul, Turkey, Erişim adresi: <https://doi.org/10.1109/ICPR.2010.579>.
- HVI-CIDNet GitHub repository, 2024. HVI-CIDNet: An Efficient Network for Low-light Image Enhancement, Erişim adresi: <https://github.com/Fedior/HVI-CIDNet>.
- Kim W., 2022. Low-light image enhancement: A comparative review and prospects, *IEEE Access*, 10, 84535-84557.
- Kreis R., 2004. Issues of spectral quality in clinical 1H-magnetic resonance spectroscopy and a gallery of artifacts, *NMR in Biomedicine*, 17(6), 361-381.
- Lei C., Tian Q., 2023. Low-Light Image Enhancement Algorithm Based on Deep Learning and Retinex Theory, *Applied Sciences*, 13(18), 10336.
- Li C., Guo C., Han L., Jiang J., Cheng M.M., Gu J., Loy C.C., 2022. Low-light image and video enhancement using deep learning: A survey, *IEEE transactions on pattern analysis and machine intelligence*, 44(12), 9396-9416.
- Matsui T., Ikehara M., 2023. Low-light image enhancement using a simple network structure, *IEEE Access*, 11, 65507-65516.
- MIRNet GitHub repository, 2024. MIRNet: Learning Enriched Features for Real Image Restoration and Enhancement, Erişim adresi: <https://github.com/swz30/MIRNet>.
- Naik V.V., Gharge S., 2016. Satellite image resolution enhancement using DTCWT and DTCWT based fusion, *International Conference on Advances in Computing, Communications and Informatics*, 21-24 September 2016, Jaipur, India, Erişim adresi: <https://doi.org/10.1109/ICACCI.2016.7732338>.
- Pan X., Li C., Pan Z., Yan J., Tan 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., Paik J., 2018. Contrast enhancement for low-light image enhancement: A survey, *IEIE Transactions on Smart Processing & Computing*, 7(1), 36-48.
- Putri A., Hartono B., Ayu N., 2024. Image Processing Techniques for Enhancing Satellite Imagery in Disaster Management, *International Journal of Computer Technology and Science*, 1(1), 14-17.
- Sharma L., Sengupta S., Kumar B., 2021. An improved technique for enhancement of satellite image, *Journal of physics: Conference series*, 1714(1), 12051.
- Singh A., Chougule A., Narang P., Chamola V., Yu F.R., 2022. Low-light image enhancement for UAVs with multi-feature fusion deep neural networks, *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
- Thriveni R., Ramashri, 2013. Satellite image enhancement using discrete wavelet transform and threshold decomposition driven morphological filter, 2013 International Conference on Computer Communication and Informatics, 4-6 January 2013, Coimbatore, INDIA, Erişim adresi: <https://doi.org/10.1109/ICCCI.2013.6466114>.
- Tian Z., Qu P., Li J., Sun Y., Li G., Liang Z., Zhang W., 2023. A survey of deep learning-based low-light image enhancement, *Sensors*, 23(18), 7763.
- Trung N.T., Le X.H., Tuan T.M., 2023. Enhancing contrast of dark satellite images based on fuzzy semi-supervised clustering and an enhancement operator, *Remote Sensing*, 15(6), 1645.
- 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*, Erişim adresi: <https://arxiv.org/abs/1808.04560>.
- Yan Q., Feng Y., Zhang C., Wang P., Wu P., Dong W., Zhang Y., 2024. You only need one color space: An efficient network for low-light image enhancement, *arXiv preprint*, Erişim adresi: <https://arxiv.org/pdf/2402.05809>.
- Yulang C., Jingmin G.A.O., Kebei Z., Yang Z., 2021. Low-light image enhancement of space satellites based on GAN, *Chinese Space Science and Technology*, 41(3), 16-23.
- Zamir S.W., Arora A., Khan S., Haya M., Khan F.S., Yang M.H., Shao L., 2020. Learning enriched features for real image restoration and enhancement, *Computer Vision–ECCV 2020: 16th European Conference*, 23–28 August 2020, Glasgow, UK, Erişim adresi: <https://arxiv.org/pdf/2003.06792>.
- Zero-DCE GitHub repository, 2024. Zero-DCE: Zero-Reference Deep Curve Estimation for Low-Light Image Enhancement, Erişim adresi: <https://github.com/Li-Chongyi/Zero-DCE>.

Zhang R., Isola P., Efros A.A., Shechtman E., Wang O., 2018. The unreasonable effectiveness of deep features as a perceptual metric, IEEE conference on computer vision and pattern recognition, 18-23 June 2018, Salt Lake City, UT, USA, Erişim adresi: <https://doi.org/10.1109/CVPR.2018.00068>.

ARAŞTIRMA VERİSİ (Research Data)

Bu çalışmada kullanılan 6 Şubat 2023 depremine ait uydu görüntüleri İstanbul Teknik Üniversitesi Uydu Haberleşme ve Uzaktan Algılama Uygulama Araştırma Merkezinden temin edilmiştir.

ÇIKAR ÇATIŞMASI / İLİŞKİSİ (Conflict of Interest / Relationship)

Araştırma kapsamında yer alan bilgiler; herhangi bir kişi, kurum ve ekipmana çıkar sağlamayı ve kişisel/kurumsal menfaat kazandırmayı amaçlamamaktadır. Bu doğrultuda çalışma kapsamında çıkar çatışması/ilişkisi ile ilgili bilgilere yer verilmemektedir.

YAZARLARIN KATKI ORANI BEYANI (Author Contributions)

- Çalışmanın tasarlanması (Designing of the study): M.U.S., I.A.
- Literatür araştırması (Literature research): Ç.K.
- Saha çalışması, veri temini/derleme (Fieldwork, collection/ compilation of data): I.A.
- Verilerin işlenmesi/analiz edilmesi (Processing/analysis of data): M.U.S., Ç.K., I.A.
- Şekil/Tablo/Yazılım hazırlanması (Preparation of figures/ tables/software): M.U.S., Ç.K.
- Bulguların yorumlanması (Interpretation of findings): M.U.S., Ç.K., I.A.
- Makale yazımı, düzenleme, kontrol (Writing, editing and checking of manuscript): M.U.S., I.A., Ç.K.