

Belirginlik-Odaklı Sanal Pozlamaya Dayalı Düşük-Aydınlıklı Görüntü İyileştirme

Saliency-Driven Low-light Image Enhancement Based on Virtual Exposure

^{*1}Yasin Demir and ¹Nur Hüseyin Kaplan

^{*1}Faculty of Engineering and Architecture, Department of Electrical and Electronics Engineering Erzurum Technical University, Türkiye.

Özet

Zayıf aydınlatmalı ortamlarda, kamera tarafından yakalanan görüntü düşük karşıtlığa ve düşük görünürlüğe sahiptir ve bu insanın görsel algısını aşırı derecede etkiler. Buradan hareketle, düşük aydınlıklı görüntülerde sıklıkla karşılaşılan yetersiz aydınlatma ve düşük karşıtlık gibi sorunları gidermek amacıyla, belirginlik-odaklı sanal pozlamaya dayalı bir yöntem önerilmiştir. Önerilen yöntem, düşük aydınlıklı giriş görüntüsünden sanal pozlama fonksiyonuyla çoklu pozlamalı görüntüler üretir. Daha sonra, çoklu pozlamalı görüntüler RGB renk uzayından HSV renk uzayına dönüştürülür. V bileşenine ait belirginlik ve karşıtlık bilgileri temel alınarak oluşturulan ağırlık haritası yardımıyla füzyon işlemi gerçekleştirilir. Füzyon işlemi RGB uzayındaki görüntü için her renk kanalına ayrı ayrı uygulanarak iyileştirilmiş görüntü elde edilir. Yöntemin etkinliğini göstermek amacıyla, Part2 Subset veri seti üzerinde literatürde sıkça kullanılan altı yöntemle kapsamlı bir karşılaştırma yapılmıştır. Nicel sonuçlar, önerilen yöntemin PSNR bakımından en iyi sonucu verdiğini, SSIM bakımından ise rekabetçi düzeyde sonuçlar elde edildiğini ortaya koymaktadır. Görsel sonuçlar, önerilen yöntemin aydınlatma iyileştirmesi, karşıtlık iyileştirmesi ve detay koruma açısından etkin ve dengeli sonuçlar ürettiğini göstermektedir.

Anahtar kelimeler: Düşük aydınlıklı görüntü iyileştirme, sanal pozlama, belirginlik, karşıtlık

Abstract

In low-light environments, the image captured by the camera has low contrast and low visibility, which greatly affects human visual perception. Therefore, a method based on saliency-oriented virtual exposure is proposed to eliminate the problems such as insufficient illumination and low contrast, which are frequently encountered in low-light images. The proposed method generates multiple-exposure images from the low-light input image via the virtual exposure function. Then, the multiple-exposure images are converted from RGB color space to HSV color space. Fusion process is performed with the help of the weight map created based on the saliency and contrast information of the V component. The fusion process is applied to each color channel separately for the image in RGB space and the enhanced image is obtained. In order to demonstrate the effectiveness of the proposed method, a comprehensive comparison is made with six methods frequently used in the literature on the Part2 Subset dataset. Quantitative results show that the proposed method reaches the best result in terms of PSNR and achieves competitive results in terms of SSIM. Visual results show that the proposed method generates effective and balanced results in terms of illumination enhancement, contrast enhancement and detail preservation.

Key words: Low-light image enhancement, virtual exposure, saliency, contrast

1. Giriş

Aydınlatması düşük ortamlar, görüntüleme sistemlerinin gürültülü, düşük görünürlük ve karşıtlıkta görüntüler üretmesine neden olurlar. Son dönemde gelişen görüntüleme teknolojilerine rağmen bu bozulmalar tamamen giderilememektedir. Bu bozulmaların kaçınılmaz olmasından ötürü düşük-aydınlıklı görüntü iyileştirme; görüntü işleme alanında önemli bir işlem olarak yerini almaktadır [1]. Düşük aydınlatma koşullarının neden olduğu bozulmalar, insanın algısını etkilemesinin yanında anlamsal segmentasyon [2], nesne tespiti [3] ve yüz tanıma [4] gibi yüksek seviye görüş işlemlerinin performansını da etkilemektedir. Dolayısıyla, düşük aydınlıklı görüntü iyileştirme metotları insan-merkezli ve makine görüş sistemleri için çok önemli hale gelmiştir.

Geleneksel düşük aydınlıklı görüntü iyileştirme yöntemleri histogram eşitleme ve Retinex teorisini temel alırlar. Histogram eşitleme tabanlı yöntemler basit ve zaman zaman etkili bir biçimde iyileştirme işlemi yapsalar dahi çoğunlukla gürültü yükseltme ve aşırı-iyileştirme gibi sorunlara neden olurlar [5]. İnsanlardaki görsel algıdan ilham alan Retineks tabanlı yöntemler, bir görüntünün aydınlatma ve yansıma bileşenlerine ayrılabilceğini varsaymaktadırlar [6,7]. Tek-ölçekli [8] ve Çok-ölçekli [9] Retineks temel Retineks teorisi yaklaşımlarıdır. Retinex teorisi, umut veren sonuçlar üretmekle beraber, iyileştirme sonuçları halo etkisi, renk distorsiyonu ve yetersiz-iyileştirme gibi bozulmalar içermektedir. Aydınlatma ve yansıma bileşenlerini elde etmek için farklı önseller [10-12] ve süzgeç yapıları [13,14] önerilmiştir. Ancak, bu metotlar, tatmin edici görsel kalite ve gülbüz sonuçlar sunamamışlardır.

Derin öğrenmede son dönemde yaşanan ilerlemeler, düşük aydınlıklı görüntülerin iyileştirilmesi için veri-odaklı metotların geliştirilmesini sağlamıştır. Evrişimli Sinir Ağları (ESA), Çekişmeli Üretici Ağlar, sıfır-referanslı Ağlar ve Transformatör Tabanlı Ağlar; eşleştirilmiş veya eşleştirilmemiş girdilerden, doğrusal olmayan öğrenmeyle, düşük aydınlıklı görüntülerin iyileştirilmesinde oldukça yüksek performans sergilemişlerdir. LLCNN [15], EnlightenGAN [16], Zero-DCE [17] ve Retinexformer [18] gibi öncü metotlar, denetimli ve denetimsiz öğrenmeyi kullanarak renk düzeltme, gürültü azaltma ve aydınlatma iyileştirmesi gibi işlemleri gerçekleştirebilmektedirler. Öğrenme tabanlı yöntemler, daha iyi sonuçlar elde etmek için enkoder-dekoder, UNet ve Otoenkoder gibi farklı yapıları kullanmaktadırlar [19]. Tüm bu ilerlemelere rağmen, düşük aydınlıklı görüntü iyileştirme metotlarının eşit olmayan aydınlatma koşulları, kenar iyileştirme ve gerçek-zamanlı uygulama gibi durumlarda zorlandıkları görülmektedir.

Bu çalışmada, düşük aydınlıklı ortamlarda yakalanan görüntülerin iyileştirilmesi amacıyla, belirginlik ve karşıtlık odaklı ağırlıklandırılmış, sanal pozlama tabanlı bir metot önerilmiştir. Önerilen metot, düşük aydınlıklı giriş görüntüsüne ait farklı sanal pozlama görüntüleri üretir. Sanal pozlamalı görüntülerin her birine ait belirginlik ve karşıtlık özelliklerine göre piksel düzeyinde ağırlıklı ortalama alma işlemi uygulanır. Ayrıca, ağırlık haritaları kenar bilgilerini koruyacak şekilde kılavuzlu filtre uygulanarak yumuşatılır. Böylece, detay kaybı olmadan belirli düzeyde karşıtlık ve aydınlatma iyileştirmesi sağlanır. Çalışmanın geri kalan kısmında, ikinci kısımda

*Corresponding author: Address: Faculty of Engineering, Department of Civil Engineering Sakarya University, 54187, Sakarya TURKEY. E-mail address: caglar@sakarya.edu.tr, Phone: +902642955752 Fax: +902642955601

önerilen yöntem hakkında detaylar verilmiştir. Üçüncü kısımda yapılan çalışmaya ait bulgular ve karşılaştırmalar sunulmuştur. Dördüncü kısımda önerilen yöntemin performansı kapsamlı bir biçimde değerlendirilmiştir. Son kısımda ise önerilen yöntemin etkinliğinin ve performansının artırılması için öneriler verilmiştir.

2. Materyal ve Yöntem

2.1. Sanal pozlama görüntülerinin oluşturulması

Düşük pozlamayla yakalanan görüntülerde, iyi aydınlatılmış alanların detayları görünür haldeyken, karanlık alanlardaki detaylar kaybolur. Bu sorundan yola çıkarak, farklı pozlama seviyelerine sahip görüntülerin birleştirilmesiyle daha zengin detaylar içeren bir çıktı görüntüsü üretebilen çoklu pozlama füzyonu tekniği geliştirilmiştir. Bu teknik, yüksek dinamik aralıklı görüntülerin üretiminde sıklıkla kullanılmaktadır [20]. Bunun yanı sıra, yalnızca tek bir düşük aydınlıklı görüntü kullanılarak üretilen farklı görüntülerin füzyonuna dayalı metotlar önerilmeye başlanmıştır. Düşük aydınlıklı görüntülerin parlaklığını artırmak için tanjant dönüşümü [21], su altı görüntü iyileştirmesi için beyaz dengesi [22] uygulanarak çoklu pozlama görüntüleri birleştirilmiştir. Bu çalışmalardan ilhamla, 2023 yılında Wang ve diğerleri yaptıkları çalışmada tek bir düşük aydınlıklı görüntüyü çoklu pozlamalı görüntü dizisine dönüştüren bir sanal pozlama iyileştirici tasarlamıştır. Önerilen sanal pozlama fonksiyonu Denklem 1'deki gibi formüle edilir [23].

$$I_i = I_0 + k_i \times I_0 \cdot (1 - I_0) \quad (1)$$

Burada, I_i i . seviye pozlama görüntüsünü, I_0 orijinal görüntüyü ve k_i i . pozlama seviyesinin kontrol katsayısını temsil etmektedir.

2.2. Ağırlık haritası

Sanal pozlamalı her bir görüntü ayrı ayrı işlenerek, piksel bazlı ağırlık haritaları elde edilmiştir. Bunun için ilk olarak RGB renk uzayındaki giriş görüntüsü HSV renk uzayına dönüştürülmüş, ardından V bileşeni üzerinde işlemler yapılmıştır. Ağırlık haritaları, karşıtlık ve belirginlik olmak üzere iki temel görsel özellik kullanılarak oluşturulmuştur. Karşıtlık, Laplace filtresi aracılığıyla hesaplanan türev bilgisi ile elde edilmiştir. Ağırlık haritasının hesaplanmasında kullanılan karşıtlık Denklem 2'deki gibi hesaplanır.

$$C_i = h * I \quad (2)$$

$$h = \begin{vmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{vmatrix} \quad (3)$$

Burada, C_i karşıtlığı, I karşıtlığı hesaplanacak olan görüntüyü ve h Laplace filtresini temsil etmektedir. Belirginlik ise Gauss filtresi kullanılarak Denklem 4'teki gibi hesaplanır.

$$S_i = |I - G_\sigma * I| \quad (4)$$

Burada, S_i belirginliği, I belirginliği hesaplanacak olan görüntüyü ve G_σ Gauss çekirdeğini temsil etmektedir. Belirlenen görsel özelliklere göre ağırlık haritası Denklem 5'teki gibi hesaplanır.

$$W_i = C_i \odot S_i \quad (5)$$

Burada, W_i ağırlık haritasını ve $\odot$ piksel bazlı çarpımı temsil etmektedir. Blok etkilerini azaltmak ve daha düzgün bir ağırlık haritası elde etmek için ağırlık haritasına kılavuzlu filtre [24] uygulanır. Filtreleme sonrasında elde edilen ağırlık haritası Denklem 6'daki gibi normalize edilir.

$$W_i = \frac{W_i}{\sum_{n=1}^N W_n + \varepsilon} \quad (6)$$

Burada, W_i normalize edilmiş ağırlığı ve ε oldukça küçük bir sabiti temsil etmektedir.

2.3. Kanal bazlı füzyon

Normalize edilen ağırlık haritaları, her RGB renk uzayındaki görüntünün her bir kanalına ayrı ayrı uygulanarak kanal bazlı ağırlıklı füzyon işlemi gerçekleştirilir. Füzyon işlemi, sanal pozlamalı görüntülerin R, G ve B kanallarının ağırlık haritalarıyla çarpımlarının toplamı ile elde edilir. İyileştirilmiş görüntü Denklem 7'deki gibi elde edilir.

$$I_{füzyon}^{Ch} = \sum_{i=1}^N W_i \odot I_i^{Ch}, \quad Ch \in \{R, G, B\} \quad (7)$$

3. DeneySEL Sonuçlar

Önerilen belirginlik-odaklı sanal pozlamaya dayalı yöntem, düşük aydınlıklı görüntüler üzerinde gerçekleştirilen deneylerle değerlendirilmiştir. Objektif bir değerlendirme yapılabilmesi için hem görsel hem de nicel olarak karşılaştırma yapılmıştır.

3.1. Veri seti

Yapılan deneysel çalışmalarda, önerilen yöntemin düşük aydınlıklı görüntüler üzerindeki etkinliğini ortaya koymak amacıyla Part2 Subset veri seti kullanılmıştır. SICE [25] veri setinin bir bileşeni olan Part2 Subset her biri çoklu pozlamalı görüntü dizilerinden oluşan 229 eşleştirilmiş görüntüden oluşur. Normal düşük aydınlıklı görüntülerin yanı sıra arkadan aydınlatmalı ve

düzensiz aydınlatmalı görüntüler içermektedir. Tüm bu özellikleri sayesinde kullanılan veri seti, önerilen yöntemin zorlu aydınlatma koşulları altında performansının değerlendirilmesi açısından uygun ve güvenilir bir test işlemi sunmaktadır.

3.2. Değerlendirme metrikleri


Önerilen yöntemin diğer yöntemlerden üstünlüğünü objektif bir şekilde değerlendirmek amacıyla, literatürde yaygın biçimde kullanılan iki temel değerlendirme metriği, tepe sinyal-gürültü oranı (Peak signal-to-noise ratio-PSNR) ve yapısal benzerlik indeksi ölçüsü (Structural similarity index measure-SSIM) [26] kullanılmıştır. PSNR, iyileştirilmiş görüntünün referans görüntü ile olan piksel bazlı benzerliğini ölçer ve dB cinsinden ifade edilir. Yüksek PSNR değeri, iyileştirme performansının daha iyi olduğunu ve bozulmanın daha az olduğunu ifade eder. SSIM değeri, piksel bazlı benzerliğin yanı sıra yapısal, parlaklık ve karşıtlık gibi özellikleri de göz önünde bulundurur. Yüksek SSIM değeri, iyileştirilmiş görüntü ve referans görüntüsü arasındaki benzerliğin yüksek olduğu anlamına gelir.

3.3. Karşılaştırmada kullanılan yöntemler

Önerilen yöntemin etkinliğini nicel ve görsel olarak değerlendirebilmek amacıyla, literatürde düşük aydınlıklı görüntü iyileştirme alanında sıkça kullanılan altı farklı yöntemle karşılaştırmalı analiz gerçekleştirilmiştir. Bu yöntemler, geleneksel iyileştirme tekniklerinden derin öğrenmeye dayalı modellere kadar farklı iyileştirme teknikleri içermektedir. SRIE [27], LIME [28], Robust Retinex [29], DeepUPE [30], SCI [31] ve GCP-MCS [32] yöntemleri objektif bir karşılaştırmalı analiz gerçekleştirmek amacıyla kullanılmıştır. Bu yöntemlerle elde edilen sonuçlar, önerilen yöntemin etkinliğini ortaya koymak için nicel ve görsel olarak sunulmuştur.

3.4. Görsel sonuçlar

Önerilen yöntemin çeşitli düşük aydınlıklı görüntüler üzerindeki görsel performansını değerlendirmek amacıyla, farklı sahnelerden seçilmiş görüntüler üzerinde karşılaştırmalar gerçekleştirilmiştir. Görsel karşılaştırma sonuçları, Part2 Subset veri setine ait düşük aydınlıklı görüntüler ve kesin referans görüntüleri ile birlikte Şekil 1’de verilmiştir.



Şekil 1. Part2 Subset veri kümesindeki görüntüler için görsel sonuçların karşılaştırılması.

Şekil 1’de, SRIE yöntemi karanlık bölgelerde gürültü, renk bozulması ve detay kaybı gibi

sorunlardan muzdariptir. LIME, bazı bölgelerde doğal olmayan renk üretimine sebep olurken detay koruma açısından iyi bir performans sergilemektedir. Robust Retinex, aydınlatma açısından iyi bir performans sergilemesine rağmen görüntünün genelinde yumuşatma yapması sebebiyle detay kaybına neden olmaktadır. DeepUPE, yeterli aydınlatma iyileştirmesi sağlayamamaktadır. SCI, yeterli aydınlatma iyileştirmesi sağlayamamakla birlikte özellikle gökyüzü gibi parlak bölgelerde renk bozulmalarının önüne geçememektedir. GCP-MCS, görüntü genelinde aşırı gürültüden muzdariptir ancak belirli ölçüde aydınlatma iyileştirmesi sağlamaktadır. Önerilen yöntem, parlak bölgelerdeki renkleri korurken belirli ölçüde aydınlatma iyileştirmesi sağlayarak, karşılaştırmada kullanılan yöntemlerden üstün performans göstermektedir.

3.5. Nicel sonuçlar

Önerilen yöntemin nicel performansı, Part2 Subset veri setinden elde edilen ortalama PSNR ve SSIM değerleri üzerinden değerlendirilmiştir. Karşılaştırmadan kullanılan yöntemler ve önerilen yöntemin nicel sonuçları Tablo 1’de verilmiştir.

Tablo 1. Part2 Subset veri kümesindeki ortalama PSNR ve SSIM değerlerinin karşılaştırması. Kalın ve altı çizili sonuçlar sırasıyla en iyi ve ikinci en iyi sonuçları temsil eder.

Metrik/Yöntem	SRIE	LIME	Robust Retinex	DeepUPE	SCI	GCP-MCS	Önerilen Yöntem
PSNR	14.42	<u>16.18</u>	15.20	14.43	15.96	15.84	16.35
SSIM	0.55	0.57	0.54	0.69	<u>0.65</u>	<u>0.65</u>	0.59

Tablo 1’de, tüm yöntemler arasında en yüksek PSNR değeri önerilen yöntem ile elde edilmiştir. Bu sonuç, önerilen yöntemin düşük aydınlıklı bölgelerdeki gürültüyü bastırmada ve genel aydınlatma iyileştirmede diğer yöntemlere göre daha başarılı sonuçlar ürettiğini göstermektedir. PSNR açısından ikinci en iyi sonuç LIME ile elde edilmektedir. SSIM değerlerine bakıldığında, en yüksek SSIM değeri, DeepUPE yöntemine aittir. İkinci en yüksek sonuç ise GCP-MCS ve SCI yöntemlerine aittir. Bu değerler, DeepUPE, SCI ve GCP-MCS yöntemlerinin diğer yöntemlere göre daha yüksek yapısal benzerliğe sahip olduğunu göstermektedir.

4. Tartışma

Bu çalışmada sunulan belirginlik-odaklı sanal pozlamaya dayalı yöntemle, hem geleneksel hem de derin öğrenme temelli yöntemlerle yapılan kıyaslamalarda görsel ve nice sonuçlar açısından dikkat çekici sonuçlar elde edilmiştir. Önerilen yöntem, tek bir düşük aydınlıklı görüntü girdisi kullanarak sanal pozlama yoluyla çoklu pozlama görüntü kümesi oluşturmada ve bu görüntüleri ağırlıklı bir füzyon süreci üzerinden birleştirmektedir.

Nicel karşılaştırma sonuçları, yöntemin özellikle PSNR değerleri bakımından literatürdeki diğer yöntemlere kıyasla daha yüksek performans sergilediğini göstermektedir. SSIM değerleri diğer yöntemlerin önünde olmamasına rağmen yeterli düzeyde yapısal benzerlik elde edilmektedir. Bu durum, önerilen yöntemin karşıtlık ve parlaklığı etkili bir şekilde iyileştirirken, yapısal benzerliğin de korunduğunu gösterir. Görsel sonuçlar incelendiğinde, aydınlatma iyileştirmesi, renk koruma ve kenar koruma gibi ölçütlerin yeterli ve dengeli bir şekilde sağlandığı

görülmektedir. Nicel ve görsel sonuçlar, önerilen yöntemin diğer yöntemlere göre daha etkin ve dengeli sonuçlar verdiğini kanıtlamaktadır.

Sonuç ve Öneriler

Bu çalışmada, düşük aydınlıklı görüntülerin iyileştirilmesinde kullanılan belirginlik-odaklı sanal pozlama tabanlı bir yöntem sunulmuştur. Önerilen yaklaşım, düşük aydınlıklı bir girdiden sanal pozlama aracılığıyla farklı pozlama seviyelerine ait görüntüler üretir. Ardından, karşıtlık ve belirginlik bilgilerinden oluşturulan ağırlık haritalarıyla füzyon işlemi gerçekleştirilerek sonuç görüntüsü elde edilir. Yöntemin performansı, görsel ve nicel olarak literatürdeki yöntemlerle kapsamlı bir şekilde karşılaştırılmıştır. Yapılan analizler, önerilen yöntemin diğer yöntemlerden üstün performans sergilediğini göstermektedir. Öğrenmeye dayalı bir modele ihtiyaç duymaması, hızlı sonuç vermesi ve gerçek zamanlı uygulamalara uygunluğu önerilen yöntemin avantajları arasındadır. Bunların yanı sıra, detay koruması ve renk korumasının iyileştirilebileceği öngörülmektedir. Buradan hareketle, bölge-temelli veya semantik farkındalığa sahip füzyon yaklaşımlarının faydalı olabileceği değerlendirilmektedir.

Kaynaklar

- [1] Shakibania H, Raoufi S, Khotanlou H. CDAN: convolutional dense attention-guided network for low-light image enhancement. *Digit Signal Processing* 2025;156:104802.
- [2] Wang H, Chen Y, Cai Y, Chen L, Li Y, Sotelo MA, et al. SFNet-N: an improved SFNet algorithm for semantic segmentation of low-light autonomous driving road scenes. *Transactions on Intelligent Transportation Systems* 2022;23(11):21405–17.
- [3] Hashmi KA, Kallempudi G, Stricker D, Afzal MZ. FeatEnhancer: enhancing hierarchical features for object detection and beyond under low-light vision. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* 2023;6725–35.
- [4] Fan Y, Wang Y, Liang D, Chen Y, Xie H, Wang FL, et al. Low-FaceNet: face recognition-driven low-light image enhancement *IEEE Transactions on Instrumentation and Measurement*. 2024.
- [5] Kim W. Low-light image enhancement: a comparative review and prospects. *IEEE Access* 2022;10:84535–57.
- [6] Li M, Liu J, Yang W, Sun X, Guo Z. Structure-revealing low-light image enhancement via robust Retinex model. *IEEE Transaction on Image Processing* 2018;27(6):2828–41.
- [7] Ren X, Yang W, Cheng WH, Liu J. LR3M: robust low-light enhancement via low-rank regularized Retinex model. *IEEE Transaction on Image Processing* 2020;29:5862–76.
- [8] Hines G, Rahman ZU, Jobson D, Woodell G. Single-scale Retinex using digital signal processors. . In *Global Signal Processing Conference* 2005;Paper 1324.
- [9] Rahman ZU, Jobson DJ, Woodell GA. Multi-scale Retinex for color image enhancement. In *Proceedings of 3rd IEEE International Conference on Image Processing* 1996;3:1003–6.
- [10] Fu X, Zeng D, Huang Y, Zhang XP, Ding X. A weighted variational model for simultaneous reflectance and illumination estimation. . In *Proceedings of The IEEE Conference on Computer Vision And Pattern Recognition* 2016;2782–90.
- [11] Guo X, Li Y, Ling H. LIME: low-light image enhancement via illumination map estimation. *IEEE Transaction on Image Processing* 2016;26(2):982–93.

- [12] Ren X, Li M, Cheng WH, Liu J. Joint enhancement and denoising method via sequential decomposition. . In 2018 IEEE International Symposium on Circuits and Systems (ISCAS) 2018;1–5.
- [13] Jobson DJ, Rahman ZU, Woodell GA. Properties and performance of a center/surround Retinex. IEEE Transaction on Image Processing 1997;6(3):451–62.
- [14] Wang S, Zheng J, Hu HM, Li B. Naturalness preserved enhancement algorithm for non-uniform illumination images. . IEEE Transaction on Image Processing 2013;22(9):3538–48.
- [15] Tao L, Zhu C, Xiang G, Li Y, Jia H, Xie X. LLCNN: a convolutional neural network for low-light image enhancement. Proc IEEE Visual Communication and Image Processing (VCIP) 2017:1–4.
- [16] Jiang Y, Gong X, Liu D, Cheng Y, Fang C, Shen X, et al. EnlightenGAN: deep light enhancement without paired supervision. IEEE Transaction on Image Processing 2021;30:2340–9.
- [17] Guo C, Li C, Guo J, Loy CC, Hou J, Kwong S, Cong R. Zero-reference deep curve estimation for low-light image enhancement. . In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2020;1780–9.
- [18] Cai Y, Bian H, Lin J, Wang H, Timofte R, Zhang Y. Retinexformer: one-stage Retinex-based transformer for low-light image enhancement. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2023;12504–13.
- [19] Guo J, Ma J, García-Fernández ÁF, Zhang Y, Liang H. A survey on image enhancement for low-light images. Heliyon 2023;9(4):e14558.
- [20] KS GR, Biswas A, Patel MS, Prasad BP. Deep multi-stage learning for HDR with large object motions. In 2019 IEEE International Conference on Image Processing (ICIP) 2019;4714–8.
- [21] Fu X, Zeng D, Huang Y, Liao Y, Ding X, Paisley J. A fusion-based enhancing method for weakly illuminated images. Signal Processing 2016;129:82–96.
- [22] Ancuti C, Ancuti CO, Haber T, Bekaert P. Enhancing underwater images and videos by fusion. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2012;81–8.
- [23] Wang W, Yan D, Wu X, He W, Chen Z, Yuan X, Li L. Low-light image enhancement based on virtual exposure. Signal Processing: Image Communication 2023;118:117016.
- [24] He K, Sun J, Tang X. Guided image filtering. IEEE Transactions on Pattern Analysis and Machine Intelligence 2012;35(6):1397–409.
- [25] Cai J, Gu S, Zhang L. Learning a deep single image contrast enhancer from multi-exposure images. IEEE Transaction on Image Processing 2018;27(4):2049–62.
- [26] Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. Image quality assessment: from error visibility to structural similarity. IEEE Transaction on Image Processing 2004;13(4):600–12.
- [27] Fu X, Zeng D, Huang Y, Zhang XP, Ding X. A weighted variational model for simultaneous reflectance and illumination estimation. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2016;2782–90.
- [28] Guo X, Li Y, Ling H. LIME: low-light image enhancement via illumination map estimation. IEEE Transaction on Image Processing 2016;26(2):982–93.
- [29] Li M, Liu J, Yang W, Sun X, Guo Z. Structure-revealing low-light image enhancement via robust Retinex model. IEEE Transaction on Image Processing 2018;27(6):2828–41.

- [30] Wang R, Zhang Q, Fu CW, Shen X, Zheng WS, Jia J. Underexposed photo enhancement using deep illumination estimation. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2019;6849–57.
- [31] Ma L, Ma T, Liu R, Fan X, Luo Z. Toward fast, flexible, and robust low-light image enhancement. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2022;5637–46.
- [32] Jeon JJ, Park JY, Eom IK. Low-light image enhancement using gamma correction prior in mixed color spaces. Pattern Recognition 2024;146:110001.