

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İSTATİSTİK ANA BİLİM DALI
VERİ BİLİMİ PROGRAMI**



**GECE SÜRÜŞ GÖRÜNTÜLERİ İYİLEŞTİRME
YÖNTEMLERİ**

Yüksek Lisans Tezi

ADEM BAKIRCI

Danışman

Dr. Öğr. Üyesi Erhan ERGÜN

SAMSUN

2025

TEZ KABUL VE ONAYI

Adem BAKIRCI tarafından, **Dr. Öğr. Üyesi Erhan ERGÜN** danışmanlığında hazırlanan “**Gece Sürüş Görüntüleri İyileştirme Yöntemleri**” başlıklı bu çalışma, jürimiz tarafından 09.07.2025 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim / Ana Sanat Dalı	Sonuç
Başkan	Dr. Öğr. Üyesi Nurettin ŞENYER	☒ Kabul
	Samsun Üniversitesi	☐ Ret
	Yazılım Mühendisliği Ana Bilim Dalı	
Üye	Doç. Dr. Gökhan KAYHAN	
	Ondokuz Mayıs Üniversitesi	☒ Kabul
	Bilgisayar Mühendisliği Ana Bilim Dalı	☐ Ret
Üye	Dr. Öğr. Üyesi Erhan ERGÜN	
	Ondokuz Mayıs Üniversitesi	☒ Kabul
	Bilgisayar Mühendisliği Ana Bilim Dalı	☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Faik Ahmet SESLİ

Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

09 /07 / 2025

Adem BAKIRCI

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : GECE SÜRÜŞ GÖRÜNTÜLERİ İYİLEŞTİRME YÖNTEMLERİ

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 18.07.2025 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 2

Tek kaynak oranı : % 1 çıkmıştır.

19 /07 / 2025

Dr. Öğr. Üyesi Erhan ERGÜN

ÖZET

GECE SÜRÜŞ GÖRÜNTÜLERİ İYİLEŞTİRME YÖNTEMLERİ

Adem BAKIRCI

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

İstatistik Ana Bilim Dalı

Veri Bilimi Programı

Yüksek Lisans, Haziran/2025

Danışman: Dr. Öğr. Üyesi Erhan ERGÜN

Gece araç kullanırken karşıdan gelen araç farlarının ışıkları sürücülerin görüşünü ciddi şekilde kısıtlayarak yol güvenliğini tehlikeye atmaktadır. Çalışmada, bu soruna çözüm olarak sürücünün yol takibini ekrandan yapabileceği aşırı parlak bölgeleri zayıflatan ve yol detaylarının netliğini koruyan görüntü iyileştirme yöntemleri geliştirilmiştir. Üç farklı dönüşüm tekniği uygulanmıştır. Bunlar Ortalamaya Adaptif Üs Yasası Dönüşümü, Standart Sapma Tabanlı Kübik Polinom Dönüşümü ve İstatistik GÜDÜMLÜ Üstel Kontrast İyileştirme. Bu metotlar arasında Ortalamaya Adaptif Üs Yasası Dönüşümü, parlaklığı bastıran en iyi yöntem olmuştur. Standart Sapma Tabanlı Kübik Polinom Dönüşümü kontrastı en iyi koruyan yöntem olmuştur. İstatistik GÜDÜMLÜ Üstel Kontrast İyileştirme, parlaklığı ve kontrastı en iyi dengeleyen yöntem olarak öne çıkmıştır. Bu yöntem, gri tonlamalı görüntülerin standart sapması ve ortalamasından yararlanarak piksel yoğunluklarını parlaklığa göre dinamik olarak ayarlar. Bu çalışma kapsamında tamamen doğal gece sürüş koşullarını ihtiva eden 400 fotoğraflık özgün bir veri seti de literatüre kazandırılmıştır. Uygulanan metotlar, piksel değerlerini optimize ederek parlama etkilerini bastırırken yoldaki diğer görüntülerin görünürlüğünü iyileştirmiştir. Üç yöntemle de yapılan testler sonucunda parlama bölgelerindeki parlaklığın sırasıyla %56, %24, %36 oranında azaldığı görülmüştür. Farklı görüntülerle yapılan testlerde SSIM metriğinde 0.824-0.980 arasında ve PSNR metriğinde 22.45-36.34 dB arasında sonuçlar alınmıştır. Tüm yöntemler farklı çözünürlüklerde 3 ms - 170 ms arasında işlem süreleriyle gerçek zamanlı uygulamalar için uygun performans sergilemiştir. Önerilen metotlar, düşük hesaplama maliyeti sayesinde gece sürüş sistemlerinde gerçek zamanlı uygulamalara entegre edilebilir. Bu çalışma, gece sürüşü esnasında karşılaşılabilecek zorluklara, istatistiksel olarak adaptif bir çözüm sunmaktadır. Bu bulgular görüntü işleme alanına katkısı ile birlikte otonom araçların geliştirilmesi ve gelişmiş sürücü destek sistemlerinin (ADAS) iyileştirilmesi için de umut vadetmektedir.

Anahtar Kelimeler : Gece sürüş güvenliği, Görüntü işleme, Gelişmiş sürücü destek sistemleri (ADAS), Parlaklık kontrolü

ABSTRACT

ENHANCEMENT METHODS FOR NIGHTTIME DRIVING IMAGES

Adem BAKIRCI
Ondokuz Mayıs University
Institute of Graduate Studies
Department of Statistics
Data Science Programme
Master of Science, June 2025
Supervisor: Dr. Erhan ERGUN

When driving at night, oncoming vehicle headlight glare jeopardizes road safety by severely restricting drivers' visibility. To address this issue, image enhancement methods have been developed that attenuate the overly bright regions where the driver can follow the road on the screen and preserve the clarity of road details. Three different transform techniques were applied. These are Mean Adaptive Exponent Law Transformation, Standard Deviation-Based Cubic Polynomial Transformation and Statistically Guided Exponential Contrast Enhancement. Among these methods, Mean Adaptive Exponent Law Transformation is the best method for suppressing brightness. Standard Deviation-Based Cubic Polynomial Transformation is the best method for preserving contrast. Statistically Guided Exponential Contrast Enhancement was found to be the best method for balancing brightness and contrast. This method dynamically adjusts pixel intensities based on brightness by utilizing standard deviation and mean values of grayscale images. Within the scope of this study, a unique dataset of 400 images, which contains completely natural nighttime driving conditions, has also been added to the literature. By optimizing pixel values, the implemented methods suppress glare effects while enhancing the visibility of other images on the road. As a result of the tests performed with all three methods, it was observed that the brightness in the glare regions was reduced by 56%, 24% and 36%, respectively. Across diverse test images, the methods achieved SSIM scores ranging between 0.824 and 0.980, while PSNR values varied from 22.45 dB to 36.34 dB. All methods exhibited suitable performance for real-time applications with processing times between 3 ms and 170 ms at different resolutions. The proposed methods can be integrated into real-time applications in night driving systems due to their low computational cost. This study offers a statistically adaptive solution to the challenges of nighttime driving. These findings show promising potential for both development of autonomous vehicles and improvements to advanced driver assistance systems (ADAS).

Keywords: Nighttime driving safety, Image processing, Advanced Driver Assistance Systems (ADAS), Brightness control

TEŞEKKÜR

Lisansüstü eğitimim süresince bana bilgi ve deneyimleri ile rehberlik eden çok değerli danışman hocam Sayın Dr. Erhan ERGÜN'e teşekkürü bir borç bilirim.

Hayatımın her anında yanımda olan sevgisini, desteğini esirgemeyen varlığıyla bana daima güç veren değerli eşime sonsuz teşekkür ederim.

Adem BAKIRCI

İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	x
1. GİRİŞ	1
1.1. Problemin Tanımı ve Önemi.....	1
1.2. Araştırmanın Amacı.....	2
2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ	4
3. MATERYAL VE YÖNTEM	14
3.1. Veri Toplama ve Ön İşleme	14
3.2. Dönüşüm Fonksiyonları	14
3.2.1. Ortalamaya Adaptif Üs Yasası Dönüşümü	14
3.2.2. Standart Sapma Tabanlı Kübik Polinom Dönüşümü	15
3.2.3. İstatistik-Güdümlü Üstel Kontrast İyileştirme	16
3.3. Görüntü Dönüşümünün Uygulanması	17
4. BULGULAR VE TARTIŞMA	20
5. SONUÇ VE ÖNERİLER.....	30
KAYNAKLAR	32
EKLER	35
ÖZGEÇMİŞ	38

SİMGELER VE KISALTMALAR

ADAS	: Gelişmiş Sürüş Destek Sistemi
AHE	: Uyarlanabilir HE
AMBE	: Mutlak Ortalama Parlaklık Hatası
AVHEQ	: Ortalama Histogram Eşitleme
BBHE	: Blok Tabanlı Çift HE
CL	: Kapalı Döngü
CLAHE	: Kontrast Sınırlı Uyarlamalı Histogram Eşitleme
CNN	: Evrişimsel Sinir Ağları
DE	: Ayrık Entropi
DNDM	: Gündüz-Gece Çift Alanlı Modülasyon
DSIHE	: Düzlemsel Alt Bölümlemeli HE
DT-CWT	: Çift Ağaç Karmaşık Dalgacık Dönüşümü
DWT	: Discrete Wavelet Transform-Ayrık Dalgacık Dönüşümü
EME	: Arttırma Ölçüsü
GAN	: Üretici Çekişmeli Ağ
HDR	: Yüksek Dinamik Aralıklı
HE	: Histogram Eşitleme
HSV	: Ton, Doygunluk, Değer
HVS	: İnsan Görsel Algısı
IR	: Kızılötesi
KCF	: Çekirdeklenmiş Korelasyon Filtreleri
LHE	: Lokal HE
LLCNN	: Düşük Aydınlatmalı Evrişimsel Sinir Ağları
LMS	: En Küçük Kareler

LOE	: Parlaklık Sırası Hatası
LPT	: Laplacian Pyramid Transform-Laplacian Piramit Dönüşümü
MBLLEN	: Çok Dallı Düşük Işık İyileştirme Ağı
MIRNet	: Çok Ölçekli Artık Ağ
MSR	: Çok Ölçekli Retinex
MSR-net	: Çok Ölçekli Retinex Ağı
MV	: Hareket Vektörleri
NSST	: Örneklenmemiş Shearlet Dönüşümü
PCNN	: Darbe Bağlantılı Sinir Ağı
PDE	: Kısmi Diferansiyel Denklem
PSNR	: Tepe Sinyal-Gürültü Oranı
ReID	: Re-identification
ROI	: Bölge İlgi Alanı
RSR	: Rastgele Püskürtmeli Retinex
SSIM	: Yapısal Benzerlik İndeks Haritası
SSR	: Tek Ölçekli Retinex
SYD	: Sentetik Veri Seti
WTHE	: Ağırlıklı HE
3DRS	: Üç Boyutlu Yinelemeli Arama

ŞEKİLLER DİZİNİ

Şekil 3.1. OAÜYD'e ait sonuçlar a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen çıkış görüntüsü	15
Şekil 3.2. SSTKPD yöntemine ait sonuçlar a) Kaynak görüntü b) SSTKPD kullanılarak elde edilen çıkış görüntüsü	16
Şekil 3.3. İGÜKİ'e ait sonuçlar a) Kaynak görüntü b) İGÜKİ kullanılarak elde edilen çıkış görüntüsü	17
Şekil 4.1. Birinci örnek görüntüye ilişkin bütün yöntemlere ait sonuçlar a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen çıkış görüntüsü c) SSTKPD kullanılarak elde edilen çıkış görüntüsü d) İGÜKİ kullanılarak elde edilen çıkış görüntüsü	25
Şekil 4.2. Birinci örnek görüntüye ilişkin bütün yöntemlere ait gri uzay histogram grafiği sonuçları a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen histogram grafiği c) SSTKPD kullanılarak elde edilen histogram grafiği d) İGÜKİ kullanılarak elde edilen histogram grafiği	25
Şekil 4.3. İkinci örnek görüntüye ilişkin bütün yöntemlere ait sonuçlar a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen çıkış görüntüsü c) SSTKPD kullanılarak elde edilen çıkış görüntüsü d) İGÜKİ kullanılarak elde edilen çıkış görüntüsü	26
Şekil 4.4. İkinci örnek görüntüye ilişkin bütün yöntemlere ait gri uzay histogram grafiği sonuçları a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen histogram grafiği c) SSTKPD kullanılarak elde edilen histogram grafiği d) İGÜKİ kullanılarak elde edilen histogram grafiği	26

TABLÖLAR DİZİNİ

Tablo 4.1. Dönüşüm tekniklerinin 5 farklı görüntüde ve veri setinde parlama bölgelerindeki ortalama parlaklık etkisi ve karşılaştırması	21
Tablo 4.2. Dönüşüm tekniklerinin 5 farklı görüntüde ve veri setinde SSIM ve PSNR karşılaştırması	22
Tablo 4.3. Farklı boyutlardaki görüntülerde işlem sürelerinin (ms) karşılaştırılması	24
Tablo 4.4. Yöntemlerin SSIM-PSNR'a göre diğer çalışmalarla karşılaştırılması	27
Tablo 4.5. Yöntemlerin SSIM-PSNR'a göre gece şartlarında görüntü işlemeye yönelik yapılan diğer çalışmalarla karşılaştırılması	28

1. GİRİŞ

1.1. Problemin Tanımı ve Önemi

Günümüzde araç sayısındaki hızlı artış, trafik kazalarında da artışa neden olmaktadır. Trafik kazalarının önemli bir kısmı da gece saatlerinde meydana gelmektedir. Bu kazaların ortaya çıkmasına sebep olabilecek etkilere biri de, karşıdan gelen araçların farlarından kaynaklanan parlama etkisidir. Parlama, sürücülerin geçici olarak görüşü kaybetmesine, tepki sürelerinin uzamasına ve yol koşullarını doğru değerlendirememelerine neden olmaktadır. Aynı zamanda karayollarında veya otoyollarda uygulanan izleme sistemlerinin ve Gelişmiş Sürücü Destek Sistemlerinin (ADAS) de etkinliğini azaltmaktadır (Erdem ve Celebi, 2024). Bu problem hem manuel sürüş hem de otonom araç sistemleri için görüntü işleme teknolojilerinin geliştirilmesini gerekli kılmaktadır. Görüş kaybı yaşayan bir sürücünün destek alabileceği bir yol monitörü, geçici tehlike anında güvenliği artırıcı bir önlem olacaktır.

Araç teknolojilerindeki ilerlemelere rağmen, gece görüş sistemleri genellikle yüksek maliyetli donanım gerektirmektedir. Bu nedenle, RGB kamera sistemlerini kullanan ve gerçek zamanlı işlenebilen yazılım tabanlı görüntü iyileştirme çözümleri, daha geniş bir araç yelpazesine uygulanabilir ve maliyet-etkin alternatifler sunabilir.

Geleneksel yöntemlerde kullanılan histogram eşitleme, retinex ve gamma düzeltme gibi teknikler, tüm görüntüye tek tip bir dönüşüm uyguladığı için parlaklık gradyanlarını bozmakta, kritik yol işaretlerinin ve diğer yol detaylarının kaybolmasına ya da görünürlüğünün azalmasına yol açmaktadır. Görüntü içinde far gibi hem aşırı parlak bölgelerin hem de yol kenarları gibi aşırı karanlık bölgelerin bulunması, geleneksel görüntü iyileştirme tekniklerinin yetersiz olmasına neden olmaktadır. Öte yandan, özellikle makine öğrenimi ve derin öğrenme tabanlı yaklaşımlar iyi sonuçlar vermiş olsa da, yüksek hesaplama maliyeti nedeniyle gerçek zamanlı sistemlerde uygulanabilirliği sınırlamaktadır (Wang vd., 2020). Bu çalışma, bu sınırlamaları aşmak için istatistik tabanlı hızlı ve adaptif bir parlaklık yönetimi sunarak hem parlak bölgelerini lokal olarak baskılayan, düşük ışık alanlarını iyileştiren ve verimli işlem maliyeti olan hızlı entegre bir yaklaşım önermektedir.

Bu çalışma, gece sürüş güvenliğini artırmak amacıyla, RGB kamera görüntüsü üzerinde parlama etkilerini adaptif olarak azaltırken yol ve çevre detaylarının görünürlüğünü bozmayan gerçek zamanlı uygulanabilir bir görüntü işleme yöntemi önermektedir. Önerilen yaklaşım, gri tonlamalı görüntülerin istatistiksel özelliklerinden ortalama ve standart sapmadan yararlanarak piksel yoğunluklarını dinamik bir şekilde ayarlar. Üç farklı dönüşüm tekniği; Ortalamaya Adaptif Üs Yasası Dönüşümü (OAÜYD), Standart Sapma Tabanlı Kübik Polinom Dönüşümü (SSTKPD) ve İstatistik GÜdümlü Üstel Kontrast İyileştirme (İGÜKİ) teknikleri geliştirilmiş ve test edilmiştir. Bu yöntemlerin yanında, tamamen doğal gece sürüş şartlarını temsil eden 400 tane gece sürüş fotoğrafından oluşan bir veri seti de oluşturularak literatüre kazandırılmıştır. Bu çalışma, hesaplama açısından verimli ve gerçek zamanlı otomotiv görüş sistemlerine uygun bir çözüm sunarak, görüntü işleme alanına katkıda bulunmayı ve otonom araçlar ile gelişmiş sürücü destek sistemlerinin (ADAS) performansını artırmayı hedeflemektedir.

1.2. Araştırmanın Amacı

Bu çalışmanın temel amacı, gece sürüşünde karşılaşılan iki kritik problemi aynı anda çözmektir:

- Kamaşma Bölgelerinin Kontrolü: Karşı yönden gelen araçların farlarının neden olduğu parlama etkisini, görüntünün lokal istatistiklerine (ortalama parlaklık μ , standart sapma σ) dayalı dinamik bir dönüşümle azaltmak.
- Düşük Işık Alanlarında Detay İyileştirme: Yol yüzeyi, yaya ve engel gibi kritik detayların kontrastını, genel parlaklık dengesini bozmadan korumaktır.

Teknik Hedefler:

- Gerçek Zamanlı Performans: CPU tabanlı sistemlerde 720p çözünürlükte ≥ 30 FPS işleme hızı sağlayarak gelişmiş sürücü destek sistemlerine entegre edilebilirlik (Tang vd., 2023).
- Donanımdan Bağımsızlık: Özel sensör veya GPU gerektirmeden standart RGB kameralarla çalışabilme (Hogervorst ve Toet, 2010).
- Gerçek zamanlı ve hesaplama açısından verimli bir görüntü iyileştirme algoritması geliştirmek.

- Otonom araçlar ve gelişmiş sürücü destek sistemleri için uygulanabilir bir çözüm sunmak.
- Mevcut araç kamera sistemlerine kolayca entegre edilebilir bir yazılım mimarisi oluşturmak.

2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ

Literatürde far parlaklığını azaltan ve karanlık görüntülerde iyileşme sağlayan farklı yöntemler vardır. Turan (2021), geleneksel metotların karanlık alanları iyileştirdiğini, ancak parlak alanları daha parlak hale getirdiğini belirtmektedir. Bu nedenle, parlamanın seviyesine göre otomatik olarak uyum sağlayan yöntemler geliştirilmelidir. Pharadornpanitchakul vd. (2014), HSV renk uzayı ve vektör büyüklüğü analizi kullanarak gece sürüşü sırasında tehlikeli far parlaması tespit eşiğini bulmayı ve kısa sürede görüşü sınırlayacak göz kamaşmalarını keşfetmeyi amaçlamıştır. Gelişmiş Sürücü Destek Sistemleri (ADAS), yol güvenliği ve gece sürüşünde sunulan konfor için büyük önem taşımaktadır. Erdem ve Celebi (2024), gece far parlamasının bu sistemlerin trafik kalitesini düşürdüğünü ve termal kameraların düşük kontrast ve renk algısı eksikliği gibi dezavantajlarını azaltmak için gündüz görüş sistemlerine eklenmesini öngören bir görüntü füzyon yöntemi önermiştir. Görüntüyü parlaklık yoğunluğuna göre üç bölgeye ayıran Mandal vd. (2021), en parlak bölgede istenilen seviyede iyileştirme sağlayamasa da en az parlamanın olduğu üçüncü bölgede arzu edilen seviyede iyileştirmeler olduğunu belirtmektedir. Pamanee ve Chaisricharoen (2013), tek kare görüntü işlemenin araç farı parlamasından kaynaklanan görüş kaybını azalttığını belirtti. Buna çözüm olarak, 3DRS (üç boyutlu yinelemeli arama) ile parlamadan etkilenmeyen karelerden yeni hareket vektörleri (MV1) oluşturarak bir video tabanlı restorasyon yöntemi önermektedir. Patil ve Phakade (2019), kavisli yollarda kör noktaları iyileştiren ve farları direksiyon hareketine veya açısına göre yatay konumlandıran bir adaptif far sistemi sunmuştur. Ayrıca literatürde görüntü iyileştirme teknikleri ile ilgili mevcut çalışmalar ve yöntemler aşağıda detaylı şekilde açıklanmıştır.

Tsagaris ve Anastassopoulos (2005), gece görüşü sistemlerini geliştirmek için gece çekilmiş kızılötesi (IR) ve görünür bölge görüntülerinin birleştirilmesi (füzyonu) üzerinde durmaktadır. Bunun amacı, elde edilen sahnelerin doğal gündüz rengi görünümüne sahip olması gereğidir. Görüntü yoğunlaştırıcılar, termal kameralar gibi mevcut gece görüş sistemleri genellikle tek renkli (gri tonlamalı veya yeşilimsi) görüntüler sunar. Bu görüntüler, yorumlanması zor olabilir, görsel yanılsamalara ve durumsal farkındalık kaybına yol açabilir. Görüntü verisinin boyutunu azaltmak için ilk adımda füzyon gerçekleştirilir. Müteakiben, renkli görüntülerin doğal olmayan görünümünü düzeltmek ve ayırım yeteneklerini artırmak için bir renk aktarımı tekniği

uygulanır. Bu teknik, doğal bir gün ışığı görüntüsünden (hedef görüntü) füzyon görüntüsüne (kaynak görüntü) renk özelliklerini aktarır. Bu, füzyon görüntülerine doğal bir gündüz görünümü veren bir yöntemdir.

Xu vd. (2007), karayollarında araç farlarının yüksek yoğunluğunun gece izleme kamera sensörlerini olumsuz etkilediğini ve bu durumun plaka veya sürücünün ekranda görünmemesine neden olduğunu ileri sürmüştür. Bu sorunu çözmek için gerçek zamanlı olarak far parlaklığını azaltabilen yeni bir parlama azaltma sistemi ve yöntemi sunmaktadır. Bu sistem, parlak bölgeleri tespit edip ışık yoğunluklarını düşürürken, araçların hızlı hareketini telafi etmek için hareket yönünde genişletme uygulayarak daha fazla detayın ve nesnenin görünmesini sağlar.

Jang vd. (2009), çok ölçekli Retinex (MSR) algoritmasında meydana gelen renk bozulmasını düzeltmeyi amaçlayan yeni bir yöntem önermektedir. Orijinal görüntüdeki baskın bir kromatiklik (belli bir renge eğilim) renk bozulmasına neden olur. Kroma, bir rengin doygunluk (saturation) ve ton (hue) bileşenlerini temsil eder. Yüksek kroma, canlı, saf renkler, düşük kroma ise soluk, griye yakın renkler anlamına gelir. Bu yöntem, çok ölçekli Retinex algoritmasında kullanılan yerel ortalama görüntüleri, renk bozulmasını azaltmak için değiştirir. Ancak, renk bozulması düzeltildiğinde elde edilen görüntünün doygunluğu genellikle düşük kalır. İşte tam bu noktada kroma telafisi (chroma compensation) devreye girer. Kroma telafisi, çıktı görüntüsünün doygunluğunu geri kazandırmak veya arttırmak için yapılır. Makalede bahsedilen çok ölçekli Retinex (MSR) algoritması, homojen olmayan aydınlatmanın etkisini azaltmayı hedefler.

Yin vd. (2010), özellikle düşük ışıklı koşullar ve gece çekilen görüntüler için, kızılötesi ve görünür görüntülerin füzyonunda renk kontrastını arttırmayı hedefler. IR ve görünür kameralar, füzyon, hedef tespiti ve durumsal farkındalık için gece görüş sistemlerinde yaygın olarak kullanılmaktadır. İnsan görsel sistemi için renk temel bir faktör olmakla birlikte uygun şekilde renklendirilmiş füzyon görüntüleri insan performansını arttırabilir. Mevcut yöntemler genellikle renk transferi kullanarak füzyon görüntülerine doğal bir görünüm kazandırır. Ancak bu yaklaşımlarda düşük renk kontrastı sorunu yaşanabilir. Önerilen yöntem, bu sorunu gidermek için doğrusal bir görüntü füzyonu şeması içerisinde renk kontrastını artıran bir yaklaşım sunar. Bunu yaparken de YUV renk uzayını kullanır. YUV uzayında Y parlaklığı, U mavi-parlaklık farkını ve V kırmızı-parlaklık farkını temsil eder. Yanlış renk füzyonunda, görünür

görüntü Y kanalına atanır. Görünür ve IR görüntüleri arasındaki fark, U kanalına atanır. IR ve görünür görüntüleri arasındaki fark ise V kanalına atanır. Görünür görüntünün Y'ye atanması, yüksek frekanslı bilginin korunmasını sağlar. U ve V kanalları, sensörler arası kontrastı yansıtır. Bu atamayla, sıcak hedeflerin kırmızıya yakın, soğuk hedeflerin ise turkuaz renkte görünmesi amaçlanır. Bu çalışmada, test edilen konfigürasyonda saniyede 10 kareye kadar işleyerek gerçek zamanlı uygulamalar için uygun olduğu ileri sürülmüştür.

Qian vd. (2012), askeri ve sivil uygulamalarda yaygın olarak kullanılan görünür ve kızılötesi gibi farklı türdeki görüntüleme sensörlerinden gelen bilgiyi birleştirme, yani görüntü füzyonu konusuna odaklanmaktadır. Özellikle, kızılötesi (IR) ve görünür görüntülerin füzyonu ile renkli gece görüşü elde etmeyi hedeflemektedir. Görünür görüntüler düşük ışıktaki düşük kontrasta sahipken, IR görüntüler sıcak hedefleri gösterebilir; füzyon, her iki sensörün tamamlayıcı bilgilerini birleştirerek daha kullanışlı görüntüler oluşturur. Mevcut renkli füzyon yöntemleri genellikle doğal renk görünümü elde etmeyi amaçlarken, makale, bu sistemlerdeki ana sorunlardan birinin, hedef ve arka plan arasındaki renk kontrastını arttırmak olduğunu vurgulamaktadır.

Lin ve Shi (2014), geleneksel çok ölçekli Retinex yöntemlerinin gürültüye karşı aşırı duyarlı olduğu ve normal veya yoğun aydınlatmalı alanlarda yetersiz kalması gerekçesiyle aşırı aydınlatılmış, aşırı az aydınlatılmış veya gürültülü alanlar altındaki gece görüntüleri için yeni çok ölçekli Retinex (MSR) yöntemi önermektedir. Önerilen yöntem, MSR' deki logaritma fonksiyonunu veri kaybını en aza indirmek için özelleştirilmiş bir sigmoid fonksiyonu ile değiştirir. Bu sigmoid fonksiyonu sınırlıdır ve kırpmaya gerektirmez. Ayrıca, yöntem koyu alanlardaki gürültüyü baskılamak ve iyi aydınlatılmış alanları korumak için ağırlık faktörleri kullanır; nihai görüntü, işlenmiş sigmoidli MSR ve orijinal görüntülerin ağırlıklı birleşiminden oluşmuştur. Ayrıca yöntem, sıkıştırılmış görüntülerdeki ayrıntı kaybı veya yapaylık içeren alanları daha iyi işlemektedir.

Lin vd. (2015), görüntü işlemede temel gereksinimler olan görüntü kontrastını ve parlaklığı dengeli iyileştirme konusundaki çelişkili hedeflere yönelik bir çözüm sunmaktadır. Histogram eşitleme (HE) tabanlı mevcut yöntemlerin bu iki gereksinimi aynı anda tatmin etmekte yetersiz kaldığı ve aşırı iyileştirme nedeniyle yapay bozulmalara (artifacts) neden olabildiği belirtilir. Bu sorunları çözmek için Ortalama Histogram Eşitleme (AVHEQ) adı verilen yeni bir boru hattı (pipeline) yaklaşımı

önerilmiştir. Bu yöntem, ilk olarak, renk bilgisini geri kazanmak için her renk kanalında dinamik germe (stretching) işlemi yapar. Ardından, görüntü histogramını ölçeklenmiş tekdüze bir histogramla ortalama sürecine tabi tutar. Bu ortalama, bilginin artırılmasını hedefler. Aşırı iyileştirme nedeniyle ortaya çıkan yapay bozulmaları azaltmak için bir histogram yeniden eşleme (re-mapping) aşaması içerir. Bu süreç, boş olmayan yoğunluk seviyelerini tüm aralığa eşit şekilde dağıtarak ani yoğunluk değişikliklerini hafifletir.

Kuang vd. (2016), gece sürüşlerinde araç tespitin düşük kontrast ve aydınlatma nedeniyle zorlu bir görev olmasından yola çıkarak, bu zorluğun üstesinden gelmek için bir yöntem önermektedir. Mevcut gelişmiş nesne algılayıcılar genellikle gündüz görüntüleri üzerinde eğitilmiş veri setlerini kullanır ve gece görüntülerindeki düşük ışık koşulları nedeniyle yetersiz kalabilir. Önerilen yöntem, Bölge İlgi Alanı (ROI - Region of Interest) çıkarma ve gece görüntü iyileştirme yaklaşımlarını birleştirmektedir. Yöntem, araç algılama için doğru ROI'leri çıkarmayı ve MSR ile görüntülerin kontrastını ve aydınlatmasını iyileştirmeyi hedeflemektedir.

Meyer vd. (2016), gece sürüş simülasyonlarında karşıdan gelen araç farlarından kaynaklanan parlamalarda insan gözünün kontrast algısındaki azalmayı gerçekçi bir şekilde simüle etmeyi amaçlamaktadır. Ticari olarak temin edilebilen standart ekranların (CRT ve LCD monitörler) ve hatta özel yüksek dinamik aralıklı (HDR) ekranların sınırlı parlaklık aralığı (0.5 cd/m^2 ile 700 cd/m^2 veya HDR için 8500 cd/m^2 'ye kadar), gerçek dünyadaki çok daha geniş parlaklık aralığını (10^{-3} cd/m^2 ile 10^5 cd/m^2 arasında aynı anda bulunabilir) fiziksel olarak yansıtmayı ve dolayısıyla insan gözünün gerçek fiziksel adaptasyonunu taklit etmeyi imkansız hale getirir. Bu sınırlamanın üstesinden gelmek için makale, algı tabanlı bir model kullanarak gece parlaması durumlarındaki adaptasyonu taklit eden bir işlem sonrası ton haritalama (tone mapping) algoritması önermektedir. Bu algoritma, parlamanın neden olduğu peçeleyici parlaklığa (veiling luminance) göre görüntü kontrastını azaltır. Parlama sona erdikçe, kontrast zamanla yumuşak bir şekilde normale döner.

Jung vd. (2017), düşük ışıklı görüntülerdeki düşük dinamik aralık, bozuk kontrast ve yüksek gürültü seviyeleri sorunlarına odaklanmaktadır. Düşük ışık koşullarında çekilen görüntülerde, görünürlük önemli ölçüde azalır ve dar bir dinamik aralığa ve düşük kontrasta sahip olurlar. Ayrıca, düşük sinyal-gürültü oranına sahip olmaları gürültü ve renk bozulmalarına yol açar. Çalışma, bu sorunları gürültüyü

artırmadan ele almak için Çift Ağaç Karmaşık Dalgacık Dönüşümüne (DT-CWT) dayalı bir yöntem önermektedir. Yöntem, görüntüyü YUV renk uzayına dönüştürdükten sonra, parlaklık (Y) kanalını DT-CWT kullanarak düşük geçiş ve yüksek geçiş alt bantlarına ayırır. YUV, insan gözünün parlaklığa (Y) renk bilgisinden (U-mavi,yeşil, V-kırmızı,mavi) daha hassas olması nedeniyle tasarlanmış bir renk modelidir. Bu özelliği sayesinde görüntü sıkıştırma (örneğin, TV yayınları veya video kodlama) ve görüntü işleme uygulamalarında sıkça kullanılır. Kontrast artırma düşük geçiş bantlarında CLAHE ile uygulanırken, gürültü azaltma yüksek geçiş bantlarında içeriğe dayalı Toplam Varyasyon (TV) difüzyonu kullanılarak yapılır. Yöntem, Memorial, Greenwich ve Eden Project gibi çeşitli veri kümelerindeki test görüntüleri üzerinde diğer yöntemlerle karşılaştırılmış ve PSNR, RMSE, DE, AMBE, Colorfulness gibi metriklerle nicel olarak değerlendirilmiştir. Test sonuçları, önerilen yöntemin diğer kontrast artırma yöntemlerine göre bilgi koruma (DE), parlaklık artırma (AMBE) ve renk doğruluğu (Colorfulness) açısından daha iyi performans gösterdiğini ortaya koymuştur.

Tao vd. (2017), düşük aydınlatmalı görüntülerdeki düşük kalite ve detayların net görünmemesi sorununu ele almaktadır. Geleneksel düşük ışık iyileştirme yöntemlerinin (histogram eşitleme (HE), Retinex tabanlı ve dehaze tabanlı yöntemler) renk sapmaları, bozulmalar, aşırı iyileştirme ve yapay bozulmalar gibi çeşitli sınırlamalara sahip olduğu belirtilmiştir. Evrişimsel sinir ağlarının (CNN) süper çözünürlük ve görüntü gürültü azaltma gibi düşük seviye görüntü işleme görevlerinde başarılı olmasına rağmen, düşük ışık iyileştirme alanında CNN kullanımının sınırlı olduğu ifade edilmiştir. Makale, bu sorunları gidermek için LLCNN (Düşük aydınlatmalı Evrişimsel sinir ağları) adlı yeni bir CNN tabanlı yöntemi önermektedir. Önerilen bu ağ, düşük ışıklı görüntüleri işleyerek normal ışık koşullarında çekilmiş gibi görünen, ancak orijinal özelliklerini ve dokularını koruyan görüntüler üretmeyi amaçlamaktadır. Yapılan deneylerde, ağ derinliğinin etkisi test edilmiş (17 katmanlı LLCNN ve 12 katmanlı LLCNN-s) ve daha derin ağın daha iyi genelleme yeteneği gösterdiği tespit edilmiştir. SSIM kaybı kullanımıyla performansın önemli ölçüde arttığı gözlemlenmiştir. LLCNN'nin, çeşitli geleneksel yöntemler (SSR, MSRCR, SRIE, LIME, DHE, CLAHE, Li'nin yöntemi) ve derin öğrenme tabanlı yöntemlerle (LLNet, VDSR tabanlı bir CNN) karşılaştırıldığı kapsamlı testler yapılmıştır. PSNR, SSIM, LOE ve SNM gibi farklı metrikler kullanılmıştır. Sonuçlar, LLCNN'nin

karşılaştırılan yöntemler arasında en üstün performansı elde ettiğini ve LLNet'e göre belirgin şekilde daha iyi sonuçlar verdiğini göstermiştir. LLCNN ile iyileştirilen görüntülerin diğer yöntemlere göre daha doğal görüldüğü ve yöntemin doğal karanlık görüntüler üzerinde de etkili olduğu belirtilmiştir.

Shi vd. (2018), gece ve düşük ışıklı koşullarda çekilen tekil görüntülerin iyileştirilmesi sorununu ele almaktadır. Düşük ışıkta çekilen görüntüler genellikle kötü görünürlük, düşük kontrast ve yüksek gürültüden muzdariptir ve derinlik bilgisinin bilinmemesi bu geliştirmeyi zorlu bir problem haline getirir. Makale, bu zorluğu aşmak için çift kanal varsayımına dayalı yeni bir yöntem önermektedir. Bu yöntem, iyi aydınlatılmış görüntülerin özelliklerini tanımlayan karanlık kanal varsayımını ve parlak kanal varsayımını temel alır. Önerilen yöntemin temel adımları arasında, girdi görüntüsünden parlak ve karanlık kanalların hesaplanması, parlak kanal kullanılarak atmosferik ışığın tahmin edilmesi, parlak kanal prioru ile geçirgenlik haritasının (transmission map) ilk tahmininin yapılması ve ardından parlak ışık nesneleri gibi sorunlu alanlardaki hatalı tahminleri düzeltmek için karanlık kanalın tamamlayıcı olarak kullanılması yer alır. Son olarak, kenar bilgilerini korumak ve hale (halo) etkilerini önlemek için tahmin edilen geçirgenlik haritası rehberli filtre kullanılarak iyileştirilir ve iyileştirilmiş görüntü, görüntü model denklemi ters çevrilerek elde edilir. Yöntemin etkinliğini değerlendirmek için çeşitli gece düşük ışıklı görüntüler üzerinde nicel ve görsel testler yapılmıştır. Testler, önerilen yöntemin altı farklı güncel yöntemle (MSR tabanlı yöntemler, tek kanal prior tabanlı yöntemler, LIME gibi) karşılaştırıldığında, kullanılan nicel kalite indeksinde önemli ölçüde daha yüksek değerler elde ettiğini ve görsel olarak daha iyi detaylar, daha doğal renkler ve daha az yapaylık sağladığını göstermiştir. Özellikle karanlık bölgelerdeki detayların diğer yöntemlere göre daha net olduğu vurgulanmıştır.

Tang vd. (2019), gözetleme, hedef takibi ve benzeri sistemlerde yaygınlaşan düşük ışıklı görüntülerdeki temel bir sorun olan aşırı parlaklığı ve etraflarındaki parlak hale (halo) etkisini ele almaktadır. Araba farları ve sokak lambaları gibi ışık kaynaklarında parlak alanlar ve haleler aşırı iyileştirilirken çevresindeki nesneler ve detaylar olumsuz etkilenebiliyor. İlk aşamada, güçlü ışık alanlarını zayıflatmak ve parlak haleyi bastırmak için ters çevrilmiş görüntüye parlak kanal varsayımı uygulanır. Ardından, zayıflatılmış görüntü, süperpiksel segmentasyon ile entegre edilmiş sis giderme (dehazing) benzeri bir algoritma kullanılarak düşük ışıklı bölgeleri

iyileştirmek için işlenir. Son olarak, iyileştirme süreci sırasında artan gürültüyü azaltmak ve görüntüyü daha da iyileştirmek için revize edilmiş bir gürültü azaltma yöntemi uygulanır.

Wang vd. (2020), düşük kontrast, düşük parlaklık, dar gri aralığı, renk bozulması ve önemli miktarda gürültüye sahip olması gibi özellikler sergileyen düşük ışık koşulları altındaki görüntülerin kalitesini artırmayı amaçlayan iyileştirme yöntemlerini incelemektedir. Makale, son yıllarda geliştirilen düşük ışık görüntü iyileştirme tekniklerini yeni bir sınıflandırmaya tabi tutarak yedi ana kategoriye ayırmıştır. Bu yöntemler, Gri Dönüşüm, Histogram Eşitleme (HE), Retinex, Frekans Alanı, Görüntü Füzyon, Sis Giderme Modeli ve Makine Öğrenmesi yöntemleridir. Çalışma, bu tekniklerin, sınıflandırmalarını, prensiplerini, değerlendirme yöntemlerini ve güncel araştırma durumunu deneysel olarak kapsamlı bir şekilde incelemektedir.

Qi vd. (2021), yirmi yıllık görüntü iyileştirme teknolojisinin gelişimini çeşitli algoritmalar, temel zorluklar, sınırlamalar, avantajlar ve dezavantajları göz önünde bulundurarak üç ana bölümde bu çalışmaları incelemiştir: denetimli (supervised) algoritmalar, denetimsiz (unsupervised) algoritmalar ve kalite değerlendirme. Denetimli yöntemler, etiketlenmiş veri setleri ile eğitilir. İlk olarak, Çok Seviyeli Özellik Füzyon Yöntemleri, düşük kaliteli görüntülerin düşük kontrast, artefakt, gürültü gibi sorunlarını ele almak için derin evrimsel sinir ağlarının (CNN) özellik çıkarma yeteneklerini kullanır. Derin bilateral öğrenme, MBLEN (Çok Dalı Düşük Işık İyileştirme Ağı), çoklu pozlama füzyonu, dikkat güdümlü ağlar, MIRNet (Çok Ölçekli Artık Ağ) gibi mimariler bu yöntemlere örnektir. İkincisi, Retinex Tabanlı Derin Öğrenme Yöntemleri, Retinex teorisini derin öğrenme ile birleştirir. MSR-net (Çok Ölçekli Retinex Ağı), LightenNet, Deep Retinex-Net ile GAN (Üretici Çekişmeli Ağ) bu yöntemlere örnek verilebilir. Üçüncü yöntem, HDR (Yüksek Dinamik Aralıklı) Görüntü Yeniden Yapılandırma, sınırlı kamera sensörü aralığını aşmak için HDR değerlerini tahmin etmeyi amaçlar.

Denetimsiz yöntemler, etiketli veri gerektirmeden görüntü kalitesini artırmak için kullanılır. Temel yaklaşımlar:

- Histogram Tabanlı Yöntemler
 - HE (Histogram Eşitleme): Global kontrast artırır ancak genellikle gri seviyelerin aşırı gerilmesine neden olur.

- AHE (Uyarlanabilir HE): Lokal kontrastı iyileştirir, detay korur.
 - LHE (Lokal HE): Görüntünün parlaklık özelliklerini korumak ve lokal detayları daha iyi geliştirmek için çalışır.
 - WTHE (Ağırlıklı HE): Histogramı ağırlıklandırarak doğal görünüm korunur.
 - Çift HE (BBHE-Blok Tabanlı Çift HE, DSIHE-Düzlemsel Alt Bölümlemeli HE): Parlaklık korunarak kontrast artırılır.
- Retinex Teorisi Tabanlı Yöntemler
- Temel Retinex: Renk sabitliği sağlar ($L = R \times B$ modeli).
 - Yol Tabanlı (RSR-Rastgele Püskürtmeli Retinex): Yüksek hesaplama maliyetli, gürültüye duyarlı.
 - Merkez/Çevre Tabanlı: SSR (Tek Ölçekli Retinex) / MSR, Gauss filtresiyle aydınlatma tahmini (hale artefaktı riski) yaparken, MSRCR (Renk Restorasyonlu MSR), renk restorasyonu ekler.
 - PDE (Kısmi Diferansiyel Denklem) ve Varyasyonel Modeller: Matematiksel optimizasyonla hale ve gürültü azaltır (L1/L2-Retinex, TV).
- Görsel Korteks Sinir Ağı Tabanlı İyileştirme
- PCNN (Darbe Bağlantılı Sinir Ağı): Kedilerin görsel korteksini taklit eder.
 - Rybak Modeli: Kenar detaylarını vurgular.

Literatürde, görüntü iyileştirme algoritmalarının performans analizinde nitel ve nicel değerlendirme metrikleri kullanılmaktadır. Nitel Değerlendirme, insan görsel algısına (HVS) dayanan subjektif bir analiz yöntemidir. Bu yöntemde, iyileştirilmiş görüntülerin görsel kalitesi, uzman değerlendiriciler tarafından sezgisel olarak analiz edilir. Ancak bu yöntemin, değerlendiricilerin kişisel yargılarından etkilenmesi ve standartlaştırılmış bir ölçütün bulunmaması gibi temel problemleri vardır. Nicel Değerlendirmede, Nitel Değerlendirmenin sınırlılıklarını aşmak için objektif ölçüm metrikleri geliştirilmiştir. Mutlak Ortalama Parlaklık Hatası (AMBE), Görüntünün Yapısal Benzerliği (SSIM), Tepe Sinyal-Gürültü Oranı (PSNR), Ayrık Entropi (DE), Artırma Ölçüsü (EME), Parlaklık Sırası Hatası (LOE) metrikleri parlaklık koruma, yapısal benzerlik, gürültü, bilgi içeriği, kontrast, doğallık gibi farklı yönleri ölçer (Qi vd., 2021).

Xu vd. (2022), yağmurlu gecelerde otomobil farlarının duran su yansımalarından kaynaklanan parlamayı ortadan kaldırmayı amaçlamaktadır. Gece sürüşü sırasında, özellikle yağmurlu günlerde, yol yüzeyindeki durgun sular ayna yüzeyleri oluşturarak

ışığı yansıtır ve sürücünün görüşünü engeller. Ayrıca, aracın kendi ışıklarının aydınlatdığı su birikintileri karşıdan gelen sürücülerin de gözlerini kamaştırabilir, bu da kazalara sebep olabilir. Mevcut parlama önleme teknolojileri (polarize ışık, sıvı kristal karartıcılar vs.) sınırlamalara sahiptir. Önerilen metot, geceleri su birikintilerini tespit etmek ve bu bilgiyi kullanarak otomobil farlarının yüksek ve kısa hüzmeye (high and low beam) geçişini ve açısını ayarlayarak parlamayı önlemek üzerine kurulu bir algoritma geliştirmektedir. Sistem, bir araç kamerası, bir kişisel bilgisayar terminali, bir kontrol modülü ve LED otomobil farlarından oluşur. Histogram eşitleme algoritması ile YOLOv5 hedef tespit yöntemini birleştiren bu yaklaşım, yağmurlu gecelerde yol üzerindeki durgun su ve çukurları etkin bir şekilde tespit ederek, farların en uygun şekilde kontrol edilmesini sağlamaktadır.

Bhalla (2023), görüntü işleme uygulamalarındaki nöral yaklaşımları ele alan bir inceleme makalesi üzerine çalışmıştır. Nesne tespiti için kullanılan farklı metodolojileri ve çeşitli çerçeveleri incelemiş, makine öğrenmesi modellerinin verimliliklerini karşılaştırarak en iyi nöral ağ modelini bulmaya çalışmıştır. Naive Bayes ve LMS (En Küçük Kareler) algoritmalarının görüntü sınıflandırmada %100 doğruluk oranına ulaştığı belirtilmiştir. Ayrıca, bazı CNN tabanlı yöntemler, ve denetimsiz modellerin bazı yaklaşımlarında %94'ün üzerinde doğruluk oranları elde ettiği ve diğer modellere göre daha iyi performans gösterdiği bulunmuştur. Denetimli makine öğrenmesi yöntemlerinin, yüksek maliyet ve zaman tüketimine rağmen, görüntü işleme için genellikle denetimsiz yöntemlerden daha verimli olduğu tespit edilmiştir. Gelecekte, Derin Öğrenme ile hibrit optimizasyon yöntemlerinin birleştirilmesi ile görüntü işleme süreçlerinin geliştirilebileceği ve hata oranlarının azaltılabileceği öngörülmektedir.

Tang vd. (2023), düşük ışıklı görüntü iyileştirme alanındaki derin öğrenme tabanlı teknikler ile yetersiz aydınlatma nedeniyle azalan görünürlük, bozuk kontrast ve yüksek gürültü sorunlarını çözmeyi amaçlayan çalışmaları incelemiştir. Bu kapsamdaki yöntemler genellikle denetimli, denetimsiz, yarı denetimli ve sıfır örnekle öğrenme (zero-shot learning) gibi dört ana kategoriye ayrılır ve bazıları görüntüyü aydınlatma ve yansıma bileşenlerine ayıran Retinex teorisine dayanır. Makale, LIME, SICE, LOL ve VE-LOL-L gibi çeşitli veri setlerindeki görüntüleri kullanarak 14 temsilci algoritmanın nesnel ve öznel değerlendirmelerini sunmuştur. Testler, tüm yöntemlerin girdi görüntülerine kıyasla görüntü kalitesi metriklerinde iyileşme

sağladığını ve özellikle denetimli öğrenme tabanlı yöntemlerin nesnel göstergelerde genellikle daha iyi performans gösterdiğini göstermiştir. Ayrıca, bu geliştirme yöntemlerinin yüz algılama gibi üst düzey görsel görevlerde performansı önemli ölçüde iyileştirdiği gözlemlenmiştir.

Li vd. (2024), araç yeniden tanımlama (Re-identification - ReID) alanındaki mevcut çalışmaların çoğunun gündüz koşullarına yönelik yapıldığını belirterek, özellikle gündüz-gece arası (cross-domain) araç yeniden tanımlamanın ihmal edildiğini ele almaktadır. Gündüz-gece araç yeniden tanımlama problemi, gece görüntülerindeki far parlaması ve düşük ışık ortamları gibi özel zorluklar içerir. Geleneksel görünür-kızılötesi (visible-infrared) ReID yöntemleri veya mevcut araç ReID yöntemleri bu zorlukları etkili bir şekilde ele almaz. Bu zorlukların üstesinden gelmek için Gündüz-Gece Çift Alanlı Modülasyon (Day-Night Dual-domain Modulation - DNDM) adı verilen yeni bir araç ReID çerçevesi önermektedir. DNDM, gündüz ve gece görüntüleri arasındaki alan farkını azaltmayı hedeflemektedir.

Lyu vd. (2024), yeşil enerji araçlarında gece sürüşü sırasında karşıdan gelen araçların farlarının neden olduğu parlama etkisini gidermeyi ve bu zorlu koşullarda yayaların algılanmasını ve takibini sağlamayı hedeflemektedir. Bu maksatla Tek Kare Farkına Dayalı Görüntü Füzyonlu Parlama Dirençli Tespit Sistemi adında yeni bir sistem önermektedir. Bu sistem, hesaplama yükünü azaltmak için video karelerini tek kare farkına dayalı olarak seçerek başlar. Ardından, seçilen kareler gürültü giderme ve görünür/kızılötesi görüntülerin hizalanması gibi ön işlemlere tabi tutulur. Parlamayı ortadan kaldırmak için, görünür ışık ve kızılötesi görüntüler, HSV renk uzayına dönüştürülerek ve NSST (Örnekleme Shearlet Dönüşümü) algoritması kullanılarak birleştirilir. Füzyon sonrası elde edilen parlamadan arındırılmış görüntüler üzerinde, geliştirilmiş bir YOLOv4 algoritması kullanılarak yayalar tespit edilir. Son olarak, tespit edilen yayalar KCF (Çekirdeklenmiş Korelasyon Filtreleri - Kernelized Correlation Filters) ve CL (Kapalı Döngü - Closed Loop) algoritmaları birleştirilerek takip edilir.

3. MATERYAL VE YÖNTEM

Bu çalışma, gece sürüşü sırasında güvenli bir yol sürüşü sağlamak amacıyla araba farlarının sebep olduğu parlak görüntüler üzerinde istatistiksel tabanlı dönüşümler kullanarak parlaklık iyileştirme ve kontrast geliştirme tekniklerini uygular. Önerilen yöntemler, gri tonlamalı görüntülerin istatistiksel özelliklerinden yararlanarak piksel yoğunluklarını uyarlamalı bir şekilde dönüştürmeyi ve dönüşüm sonuçlarını ortalama parlaklık analizi, SSIM, PSNR ve işlem süreleri ile değerlendirmeyi içermektedir. Yöntem, üç farklı dönüşüm tekniğinin tasarımı, uygulanması, görselleştirilmesi ve parlaklık seviyelerinin nicel analizini kapsamaktadır. Aşağıda, bu süreç adım adım açıklanmıştır.

3.1. Veri Toplama ve Ön İşleme

Çalışmada, gece sürüşü koşullarını temsil eden 400 tane görüntü veri seti oluşturulmuştur. Bu veri seti bundan sonra çalışma yapacaklar için de önemli bir veri desteği sağlayacaktır. Veri setine bu linkten ulaşılabilir (<https://www.kaggle.com/datasets/adembakrc/nighttime-driving>). Görüntü, OpenCV kütüphanesi aracılığıyla yüklenmiş ve işlenmek üzere hazırlanmıştır. Görüntü, analiz ve dönüşüm işlemleri için gri ve RGB formatına dönüştürülmüştür. Gri tonlama işlemi, parlaklık ve kontrast dağılımının istatistiksel analizini kolaylaştırmak amacıyla gerçekleştirilmiştir.

Her bir gri tonlamalı görüntü üzerinde, piksel yoğunluklarının ortalaması ve yoğunluk değerlerinin ortalamadan sapmasını gösteren standart sapması gibi istatistiksel özellikler hesaplanmıştır. Bu parametreler, dönüşüm fonksiyonlarının dinamik olarak uyarlanması ve parlaklık seviyelerinin değerlendirilmesi için temel referans değerleri olarak kullanılmıştır.

3.2. Dönüşüm Fonksiyonları

Gece sürüşü görüntülerinde parlama etkisini azaltmak ve yol detaylarını korumak için üç farklı dönüşüm fonksiyonu tasarlanmıştır. Tüm bu fonksiyonlar, 0-1 aralığında normalize edilmiştir.

3.2.1. Ortalamaya Adaptif Üs Yasası Dönüşümü

İlk dönüşüm fonksiyonu (OAÜYD), klasik gamma düzeltmesinin bir varyasyonu olup görüntünün ortalama yoğunluğuna göre adaptif parametre kullanan

bir üs kanunu dönüşümüdür. Burada, x giriş yoğunluğunu, μ ise gri tonlamalı görüntünün ortalama parlaklığını temsil eder. Ortalamanın karekökü, üs değerini uyarlamalı bir şekilde ayarlayarak düşük ışıklı bölgelerde detayların korunmasını ve yüksek ışıkta aşırı parlaklığı baskılamayı amaçlamaktadır.

$$y = \frac{x^{\sqrt{\mu/50}}}{2} \quad (3.1)$$



Şekil 3.1. OAÜYD'e ait sonuçlar a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen çıkış görüntüsü

3.2.2. Standart Sapma Tabanlı Kübik Polinom Dönüşümü

İkinci dönüşüm fonksiyonu (SSTKPD), standart sapmaya (σ) bağlı bir kübik polinom kullanmaktadır. Kübik polinom dönüşümü, özellikle orta kontrastlı görüntüler için etkili olan doğrusal olmayan iyileştirme sağlar. Kübik terimin negatif katsayısı, standart sapmanın tersi ile ağırlıklandırılarak, dönüşümün daha yüksek ortalama parlaklığa sahip görüntülerde karanlık bölgeleri daha agresif bir şekilde iyileştirmeyi sağlar. Böylece çeşitli görüntü türleri arasında dengeli iyileştirme ve yoldaki diğer detayların görüntüsünün korunmasını sağlar.

$$y = -\frac{x^3}{\sigma} + x \quad (3.2)$$



Şekil 3.2. SSTKPD yöntemine ait sonuçlar a) Kaynak görüntü b) SSTKPD kullanılarak elde edilen çıkış görüntüsü

3.2.3. İstatistik-Güdümlü Üstel Kontrast İyileştirme

Üçüncü dönüşüm fonksiyonu (İGÜKİ), hem ortalama yoğunluğu hem de standart sapmayı kullanan daha karmaşık bir üstel fonksiyondur. Bu üstel dönüşüm, özellikle düşük kontrastlı ve zayıf detay görünürlüğüne sahip görüntüler için uygun olan daha agresif kontrast iyileştirmesi sağlar. Hem ortalama (μ) hem de standart sapma (σ) dikkate alınarak dönüşümün hem ortalama parlaklığa hem de giriş görüntüsünün kontrast aralığına uyum sağlamasını sağlayarak, çeşitli görüntü özelliklerine oldukça duyarlı hale getirir. İstatistik-Güdümlü Üstel Kontrast İyileştirmesi, kontrastın doğal bir şekilde korunmasına olanak tanır.

$$y = \frac{(e^{x(1+(\sigma/2000))} - 1)}{((e^{1+(\sigma/2000)} - 1) + (\mu/2000))} \quad (3.3)$$



Şekil 3.3. İGÜKİ'ye ait sonuçlar a) Kaynak görüntü b) İGÜKİ kullanılarak elde edilen çıkış görüntüsü

3.3. Görüntü Dönüşümünün Uygulanması

Dönüşüm fonksiyonları, RGB görüntülerin her bir kanalına (kırmızı, yeşil, mavi) ayrı ayrı uygulanmıştır. Dönüşüm fonksiyonlarının uygulanması, iyileştirme süreci üzerinde hassas kontrol sağlamak için piksel bazlı bir yaklaşım izler. Çalışma altı adımdan oluşur:

1. Adım: Giriş görüntüsü OpenCV kütüphanesi kullanılarak okunur, BGR (Mavi-Yeşil-Kırmızı) kanalından RGB ve istatistiksel hesaplamalar için gri kanala dönüştürülür.
2. Adım: Gri görüntünün genel aydınlık seviyesini temsil eden ortalama piksel yoğunluğu (μ) ve piksel yoğunluklarının standart sapması (σ) hesaplanır.
3. Adım: RGB görüntüsü, dönüşüm işlemlerini kolaylaştırmak için 0-1 aralığına normalize edilir.
4. Adım: Her dönüşüm fonksiyonu için, önceden hesaplanmış adaptif parametreleri kullanarak giriş yoğunluk değerlerinden (x) çıkış yoğunluk değerlerine (y) bir haritalama oluşturulur.
5. Adım: Normalize edilmiş görüntüdeki her piksel ayrı ayrı işlenir, dönüşüm fonksiyonu yoğunluk değerine uygulanır.
6. Adım: Kırmızı ve yeşil kanala herhangi bir işlem uygulanmaz iken mavi kanalın yoğunluğu, renk dengesini korumak ve parlama etkisini daha fazla

bastırmak amacıyla 0.3 katsayısı ile çarpılmıştır. Bu işlem, görsel algıda doğal bir iyileşme sağlamayı ve gece sürüşü görüntülerinde gerçekçi bir renk temsilini korumayı amaçlamaktadır.

Gece görüşünde far ışıklarından kaynaklı aydınlık ve karanlık bölgeler arasında oluşan aşırı kontrast göz merceğini küçültüp algıyı zayıflatır. Kameralarda insan gözündeki gibi bir duyarlılık yoktur; sadece ölçülen değer iletilir. Ancak gece görüntülerinde aşırı parlaklığı azaltıp karanlık bölgeleri aydınlık yapmaya yetecek bilgi 24 bit RGB görüntülerde elde edilememektedir. Yapılabilecek en uygun işlem ışık ile atmosfer arasındaki etkileşim üzerinden yola çıkarak görüntüde ihtiyacımız olan unsurları ön plana çıkarmak olmalıdır.

Işık, atmosfere girdiğinde mor, mavi ve yeşilin daha kısa görünür dalga boyları, sarı, turuncu ve özellikle kırmızının daha uzun dalga boylarından daha fazla atmosferik gazlar tarafından dağıtılır. Mor, mavi ve yeşilin dağınık dalgaları göze her yönden çarpar. İnsan gözü mavi ışığa daha duyarlı olduğundan, bu dalgalar birlikte bakıldığında, etrafımızdan gelen mavi hissini üretir. Katedilen mesafede atmosferik yoğunluk yükselirse uzun dalga boylu kırmızı ışık daha uzun mesafe kateder. Bu nedenle gün batımında kırmızı güneş görülür (Jiang, 2014). Gece görüşü için yapılabilecek en uygun yaklaşım uzak mesafeden gelen görüntü detaylarını kaybetmemek ve gözümüzün duyarlı olduğu mavi ışığı kontrol altına almaktır. Bu çalışmada, uzak mesafe görüntüsünü taşıyan ve saçılım yapsa bile insan algısını yanıltmayan kırmızı ve yeşil renklere herhangi bir işlem yapılmayacak ancak eşğin aşıldığı durumlarda mavi kanalda hesaplanmış operasyonlar yapılacaktır.

Kısa dalga boyuna sahip mavi ışık, gözün retina tabakası üzerinde daha fazla dağılmaya neden olur. Gece sürüşünde araç farları, sokak aydınlatmaları veya karşıdan gelen taşıtlardan yayılan mavi tonlu ışıklar gözde kamaşma ve bulanıklığa yol açabilir. Sarı renk, bu dağılmayı en aza indirmek ve kontrastı artırmak için mavi ışığın etkisini zayıflatarak görüşü netleştirir. Böylece sürücüler yol işaretlerini, yol detaylarını ve diğer taşıtları daha net bir şekilde görebilmektedir.

Dönüşüm esnasında hesaplama maliyeti optimizasyonu için float 32-bit veri tipi ve for döngüsü yerine numpy kütüphanesi vektörel indeksleme kullanılmıştır. Çalışmada kullanılan görüntülerin görüntü çözünürlüğü 1080x1920'dir. Çalışmaya ait kodlamalar Python dili ile yapılmıştır ve Google Colab kullanılmıştır. 11th Gen Intel(R) Core(TM) i5-11400H @ 2.70 GHz İşlemci, 32 GB RAM, Nvidia GeForce

GTX 1650 Ekran Kartı ve 64 bit Windows 11 Pro işletim sistemine sahip bilgisayarda çalıştırılmıştır.

Çalışmada geliştirilen algoritmaların kaynak kodları, araştırmacıların incelemesi için GitHub'da halka açık olarak paylaşılmıştır: (<https://github.com/edmbkrc/DATA-SCIENCE-THESIS>). Tüm yöntemlerin nicel karşılaştırmalarını gösteren ek grafikler ve görsel sonuçlar, makalenin EKLER kısmında detaylı olarak sunulmaktadır.

4. BULGULAR VE TARTIŞMA

Bu çalışma, gece sürüşü görüntülerinde parlama etkisini azaltmak ve yol detaylarının görünürlüğünü korumak amacıyla geliştirilen Ortalamaya Adaptif Üs Yasası Dönüşümü, Standart Sapma Tabanlı Kübik Polinom Dönüşümü ve İstatistik GÜdümlü Üstel Kontrast İyileştirme tekniklerinin performansını değerlendirmiştir. Bulgular, 400 gece sürüşü fotoğrafından oluşan bir veri seti üzerinde yapılan parlaklık analizine dayanmaktadır. Parlaklık ölçümleri, parlama bölgeleri için hesaplanmış ortalama piksel yoğunluk değerleri, SSIM (Yapısal Benzerlik İndeks Haritası) ve PSNR (Tepe Sinyal-Gürültü Oranı) ve işlem süreleri üzerinden gerçekleştirilmiş ve dönüşüm öncesi kaynak görüntü ile dönüşüm sonrası sonuçlar karşılaştırılmıştır. SSIM ve PSNR, görüntü iyileştirme algoritmalarının performansını ölçmek için kullanılan iki temel metriktir. SSIM, görüntüler arasındaki yapısal, aydınlık ve kontrast benzerliğini insan algısına yakın şekilde ölçer. SSIM değeri 0 ile 1 arasındadır; 1'e ne kadar yakın olursa, iki görüntü o kadar benzerdir. Bu yöntem, insan görsel algısını etkili bir şekilde simüle edebilir ve değerlendirme sonucu insan gözünün öznel algısına çok yakındır. Piksel hataları yerine görsel içerik bütünlüğüne odaklanır. PSNR görüntü sıkıştırma veya iyileştirme işlemlerindeki gürültü ve bozulma miktarını ölçer. Orijinal ve işlenmiş görüntü arasındaki piksel bazlı hataları değerlendirir. PSNR değeri ne kadar büyükse, işlem öncesi ve sonrası görüntüler arasındaki fark o kadar küçüktür. Aşağıda, SSIM ve PSNR formülleri ve elde edilen bulgular detaylı bir şekilde sunulmuştur.

$$SSIM(x, y) = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4.1)$$

- μ_x : x görüntüsünün ortalama piksel değeri
- μ_y : y görüntüsünün ortalama piksel değeri
- σ_x : x görüntüsünün standart sapması
- σ_y : y görüntüsünün standart sapması
- σ_{xy} : x ve y görüntüleri arasındaki kovaryans
- C_1, C_2 : Bölmeyi sabitlemek için küçük sabitler

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (4.2)$$

- MAX_I : Görüntüdeki en yüksek piksel değeri

- MSE: Ortalama karesel hata

Tablo 4.1. Dönüşüm tekniklerinin 5 farklı görüntüde ve veri setinde parlama bölgelerindeki ortalama parlaklık etkisi ve karşılaştırması

	Orjinal Parlaklık	Ortalamaya Adaptif Üs Yasası Dönüşümü		Standart Sapma Tabanlı Kübik Polinom Dönüşümü		İstatistik GÜdümlü Üstel Kontrast İyileştirme	
		Yeni Parlaklık	Değişim Yüzdesi (%)	Yeni Parlaklık	Değişim Yüzdesi (%)	Yeni Parlaklık	Değişim Yüzdesi (%)
Görüntü 1	171	73	57	129	25	111	35
Görüntü 2	173	64	63	133	23	113	34
Görüntü 3	166	70	58	127	24	106	36
Görüntü 4	160	73	55	122	24	102	37
Görüntü 5	173	68	61	138	20	120	31
Veri Seti Ortalama	163	72	56	124	24	105	36

Tablo 4.1.'de örnek olarak beş farklı görüntü için kaynak görüntülerin parlaklık değerlerini, her yöntemle elde edilen yeni parlaklık değerlerini ve bu değişimlerin yüzdesel oranlarını sunmaktadır. Ayrıca, 400 görüntüden oluşan veri seti için ortalama değerler hesaplanarak yöntemlerin genel performansı analiz edilmiştir. Tablo 4.1.'de, beş görüntünün orijinal parlaklık değerleri 160 ile 173 arasında değişmektedir, ortalama olarak 169 birim olarak ve 400 tane görüntünün de ortalaması 163 birim olarak hesaplanmıştır. Bu değer, gece sürüşü koşullarında karşı yönden gelen farların neden olduğu yüksek yoğunluklu parlama alanlarını temsil etmektedir. Üç yöntem yoğun parlama bölgelerindeki ortalama parlaklık değerlerini %24, %36 ve %56 oranlarında düşürmüştür.

Ortalamaya Adaptif Üs Yasası Dönüşümü parlama bölgelerindeki parlaklık değerlerini önemli ölçüde azaltmıştır. Bu yöntem, ortalama parlaklığı 163'ten 72'ye

düşürmüş, bu da yaklaşık %56'lık bir azalma anlamına gelmektedir. Karşıdan gelen araçların farlarının neden olduğu yoğun parlaklık önemli ölçüde baskılanmıştır.

Standart Sapma Tabanlı Kübik Polinom Dönüşümü parlama bölgelerindeki parlaklık değerlerini azaltmıştır. Bu yöntem, ortalama parlaklığı 163'ten 124'e düşürmüş, bu da yaklaşık %24'lük bir azalma anlamına gelmektedir. SSTKPD, karşıdan gelen araçların farlarının neden olduğu yoğun parlaklığı diğer yöntemler arasında en az baskılayan yöntemdir.

İstatistik Güdümlü Üstel Kontrast İyileştirme yöntemi parlama bölgelerindeki parlaklık değerlerini azaltmıştır. Bu yöntem, ortalama parlaklığı 163'ten 105'e düşürmüş, bu da yaklaşık %36'lık bir azalma anlamına gelmektedir. İGÜKİ, karşıdan gelen araçların farlarının neden olduğu yoğun parlaklığın OAÜYD yönteminden sonra en çok baskılandığı yöntemdir.

Tablo 4.2. Dönüşüm tekniklerinin 5 farklı görüntüde ve veri setinde SSIM ve PSNR karşılaştırması

	Ortalamaya Adaptif Üs Yasası Dönüşümü		Standart Sapma Tabanlı Kübik Polinom Dönüşümü		İstatistik Güdümlü Üstel Kontrast İyileştirme	
	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
Görüntü 1	0.957	22.61	0.985	35.65	0.842	25.33
Görüntü 2	0.627	15.25	0.988	30.50	0.839	20.39
Görüntü 3	0.942	19.07	0.985	33.72	0.845	23.93
Görüntü 4	0.898	24.83	0.982	37.19	0.839	26.83
Görüntü 5	0.638	15.88	0.986	30.78	0.835	20.48
Veri Seti Ortalama	0.824	22.45	0.980	36.34	0.843	26.09

Tablo 4.2.'de sunulan beş farklı örnek görüntü ve 400 farklı görüntüden oluşan veri seti üzerinde uygulanan üç dönüşüm tekniğinin SSIM ve PSNR performans karşılaştırmaları, yöntemlerin tutarlılığı ve etkinliği hakkında önemli bilgiler

sunmaktadır. Beş tane görüntü örnek olması için verilmiştir. Veri Seti Ortalama satırı veri setinde bulunan 400 görüntünün ortalama değerleridir.

Standart Sapma Tabanlı Kübik Polinom Dönüşümü, tüm görüntülerde diğer iki yönteme göre belirgin şekilde üstün performans sergilemiştir. SSIM değerlerinin 0.982 ile 0.988 arasında değişmesi ve ortalama 0.98 olarak ölçülmesi, bu yöntemin görüntülerin yapısal bütünlüğünü neredeyse mükemmel şekilde koruduğunu göstermektedir. Aynı şekilde, 30.50 dB ile 37.19 dB aralığındaki ve ortalama 36.34 olan PSNR değerleri, görüntü kalitesindeki bozulmaların minimal düzeyde olduğunu kanıtlamaktadır. Bu sonuçlar, kübik polinom yönteminin farklı içeriklere sahip görüntülerde bile tutarlı ve güvenilir sonuçlar ürettiğini ortaya koymaktadır.

Ortalamaya Adaptif Üs Yasası Dönüşümü ise performans açısından daha değişken sonuçlar vermiştir. Görüntü 1, 3 ve 4'te 0.957, 0.942 ve 0.898 SSIM değerleri elde ederken, Görüntü 2 ve 5'te bu değer 0.627 ve 0.638'e kadar düşmüştür. Benzer şekilde, PSNR değerleri de 15.25 dB ile 24.83 dB arasında önemli ölçüde değişkenlik göstermiştir. Veri setindeki görüntülerin ortalama 0.824 ve 22.45 olarak ölçüldüğü gözlemlenmiştir. Bu durum, OAÜYD yönteminin SSTKPD yöntemiyle karşılaştırıldığında bazı görüntü türlerinde yetersiz kaldığını ve genelleme kabiliyetinin sınırlı olabileceğini ve detaylarda kontrast kaybının olabileceğini düşündürmektedir.

İstatistik Güdümlü Üstel Kontrast İyileştirme yöntemi ise parlaklık ve kontrast optimizasyonu konusunda daha dengeli bir performans sergilemiştir. SSIM değerleri 0.835 ile 0.845 arasında değişirken, PSNR değerleri 20.39 dB ile 26.83 dB aralığında kalmıştır. Veri setindeki görüntülerin ortalama SSIM ve PSNR değerleri 0.843 ve 26.09 olarak ölçüldüğü gözlemlenmiştir. Bu sonuçlar, yöntemin kabul edilebilir ancak özellikle kübik polinom yöntemiyle karşılaştırıldığında, bu yöntemin görüntü kalitesi ve detay koruma açısından yetersiz kaldığı açıkça görülmektedir.

Tablo 4.3. Farklı boyutlardaki görüntülerde işlem sürelerinin (ms) karşılaştırılması

	3200x2400	2048x1536	1280x720	1024x720	960x540	600x400
OAÜYD	143	55	14	11	7	4
SSTKPD	125	46	13	11	7	3
İGÜKİ	170	57	13	11	7	4


Tablo 4.3, farklı çözünürlükteki görüntüler için önerilen üç tekniğin hesaplama performansını karşılaştırmaktadır.

Bu çalışmadaki önerilen yöntemlerin işlem süresi verileri sadece dönüştürme fonksiyonlarının uygulama safhasını kapsamaktadır. Görüntülerin okunması ve gösterilmesi bu süreye dahil değildir. Ayrıca bu süreler elde edilen en iyi sürelerdir. Çalışmaya ait kodlamalar Python dili ile yapılmıştır ve Google Colab kullanılmıştır. 11th Gen Intel(R) Core(TM) i5-11400H @ 2.70 GHz İşlemci, 32 GB RAM, Nvidia GeForce GTX 1650 Ekran Kartı ve 64 bit Windows 11 Pro işletim sistemine sahip bilgisayarda çalıştırılmıştır.


ADAS sistemleri canlı video akışını işleyip sürücüyü neredeyse anında geliştirilmiş bir görüntü sunabilmelidir. Zira sürüş sırasında zaman faktörü hayati önem taşır ve canlı video yakalama ile yeniden yapılandırılmış video gösterimi arasında büyük bir gecikme olmaması gerekmektedir (Mandal vd., 2021).

Çözünürlük arttıkça işlem sürelerinin de arttığı görülmektedir. Üç yöntem de benzer işlem sürelerine sahipken, çözünürlük arttıkça özellikle SSTKPD yönteminin diğerlerine göre daha hızlı olduğu görülmektedir. Gerçek zamanlı görüntü işleme için 30 FPS hedeflenen ve ideal kabul edilen kare hızıdır (Tang vd., 2023). Daha düşük FPS değerleri (örneğin 10 FPS gibi) bazı durumlarda gerçek zamanlı olarak adlandırılrsa da, modern uygulamalar ve özellikle yüksek hızlı hareket eden senaryolarda yeterli görülmemektedir (He vd., 2012). 720p çözünürlüğünde işlem süreleri 11 ile 14 milisaniye arasında değişmektedir. Bu değerler 71 FPS ve 90 FPS arasına tekabül etmektedir. Bu sonuçlar, farklı matematiksel karmaşıklığa sahip olmalarına rağmen, önerilen yöntemlerin gerçek zamanlı uygulamalar için 30 FPS'nin üzerinde 71 ile 90 FPS ile etkili hesaplama verimliliği sunduğunu göstermektedir.


Önerilen yöntemlerin diğer yöntemlerle karşılaştırıldığında düşük işlem sürelerine sahip olması, bunların gerçek zamanlı görüntü işleme sistemlerinde (örneğin araç kameraları veya sürücü destek sistemleri) rahatlıkla kullanılabileceğini göstermektedir.




Şekil 4.1. Birinci örnek görüntüye ilişkin bütün yöntemlere ait sonuçlar a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen çıkış görüntüsü c) SSTKPD kullanılarak elde edilen çıkış görüntüsü d) İGÜKİ kullanılarak elde edilen çıkış görüntüsü



Şekil 4.2. Birinci örnek görüntüye ilişkin bütün yöntemlere ait gri uzay histogram grafiği sonuçları a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen histogram grafiği c) SSTKPD kullanılarak elde edilen histogram grafiği d) İGÜKİ kullanılarak elde edilen histogram grafiği



Şekil 4.3. İkinci örnek görüntüye ilişkin bütün yöntemlere ait sonuçlar a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen çıkış görüntüsü c) SSTKPD kullanılarak elde edilen çıkış görüntüsü d) İGÜKİ kullanılarak elde edilen çıkış görüntüsü



Şekil 4.4. İkinci örnek görüntüye ilişkin bütün yöntemlere ait gri uzay histogram grafiği sonuçları a) Kaynak görüntü b) OAÜYD kullanılarak elde edilen histogram grafiği c) SSTKPD kullanılarak elde edilen histogram grafiği d) İGÜKİ kullanılarak elde edilen histogram grafiği

Şekil 4.1, 4.2, 4.3 ve 4.4'deki görüntü ve histogram grafikleri incelendiğinde, kaynak görüntülerde (Şekil 4.1, 4.3 (a)) renk tonu, koyu mavi ve siyahlarla baskın olup, araç farlarından kaynaklanan parlamalar mevcuttur. Görüntülerde, sınırlı görünürlük ve yüksek kontrastlı aydınlatma durumu söz konusudur. OAÜYD yöntemi

(Şekil 4.1, 4.3 (b)) parlaklığı agresif şekilde azaltırken yol detaylarını da belirsizleştirdiği, özellikle gökyüzünün ve yolun sağındaki ağaçların görünürlüğünü azalttığı görülmektedir. Histogram grafikleri (Şekil 4.2, 4.4 (b)) 100'ün üzerindeki piksellerin baskılandığı ve 0 ila 50 piksel arasında şiddetli bir piksel yoğunluğunun olduğu ve yol detaylarının da daha koyu renkle baskılandığı gözlemlenmiştir. SSTKPD yöntemi (Şekil 4.1, 4.3 (c)) parlaklığı azaltırken yol detayları, gökyüzü ve ağaç görüntülerinin netliğini korumuştur. Histogram grafikleri (Şekil 4.2, 4.4 (c))'de bütün piksellerde dengeli bir baskılanma olduğu ve yol detaylarının görünürlüğü korunduğu gözlemlenmiştir. İGÜKİ yöntemi (Şekil 4.1, 4.3 (d)) parlaklığı OAÜYD yöntemi kadar agresif olmasa da azaltmış, gökyüzü rengini daha fazla koyulaştırmış, büyük ağacın yanındaki üçlü ağaç dalını daha az görünür hale getirmiştir. Histogram grafikleri (Şekil 4.2, 4.4 (d))'de 100'ün üzerindeki pikseller orta seviyede baskılanmış ve 0 ila 50 piksel arasında bir yoğunluk olduğu gözlemlenmiştir.

Tablo 4.4. Yöntemlerin SSIM-PSNR'a göre diğer çalışmalarla karşılaştırılması

	OAÜYD	SSTKPD	İGÜKİ	Turan, (2021)	Erdem ve Celebi (2024)	LPT	DWT	Pamane ve Chaisricharoen (2013)
SSIM	0.824	0.980	0.843	0.762	0.741	0.737	0.796	-
PSNR	22.45	36.34	26.09	22.41	-	-	-	33.63

Bu tabloda karşılaştırılan yöntemler doğrudan gece şartlarında araba farlarıyla ilgili yapılan çalışmalardan alınmıştır. Ortalamaya Adaptif Üs Yasası Dönüşümü, Standart Sapma Tabanlı Kübik Polinom Dönüşümü ve İstatistik GÜDÜMLÜ Üstel Kontrast İyileştirme için Tablo 4.2'de gösterilen 400 tane farklı görüntünün ortalama değerleri alınmıştır. Turan (2020)'nin çalışmasında Figure 7 şeklindeki en iyi SSIM ve PSNR değerleri alınmıştır. Erdem ve Celebi (2024), önerdikleri LPT 0.747 ve DWT 0.741 SSIM değerleriyle diğer LPT (Laplacian pyramid transform-Laplacian piramit dönüşümü) ve DWT (Discrete wavelet transform-Ayrık dalgacık dönüşümü) metotlarını karşılaştırmıştır. Pamane ve Chaisricharoen (2013) çalışmasındaki TABLE III Restored frame satırındaki PSNR değerlerinin ortalaması esas alınmıştır.

Tablo 4.4'te gece sürüşü esnasında araba farları ile ilgili yapılan çalışmalarda SSIM değerlerine bakıldığında üç yöntemin de diğer yöntemlerden daha başarılı olduğu görülmektedir. PSNR değerlerinde SSTKPD yöntemi diğer yöntemlerle karşılaştırıldığında en başarılı yöntem olduğu görülmektedir.

Tablo 4.5. Yöntemlerin SSIM-PSNR'ye göre gece şartlarında görüntü işlemeye yönelik yapılan diğer çalışmalarla karşılaştırılması

	SSIM	PSNR
OAÜYD	0.824	22.45
SSTKPD	0.980	36.34
İGÜKİ	0.843	26.09
Lv	0.94	25.24
MBLLEN	0.90	24.21
GLADNet	0.90	24.57
Ying	0.80	19.21
SRIE	0.56	13.83
CRM	0.86	18.81
BIMEF	0.85	17.36
CegaHE	0.81	19.09
NPE	0.81	17.92
WT	0.52	11.54

Bu tabloda karşılaştırılan yöntemler doğrudan gece araba farlarıyla ilgili olmayıp gece şartlarında görüntü işlemeye yönelik yapılan çalışmalardan alınmıştır. Lv, MBLLEN, GLADNet, Ying ve SRIE metotlarının değerleri Qi vd. (2021) çalışmasında Tablo 1'den alınmıştır. 19 yöntem arasından en iyi 4 değer ve en kötü 1 değer (SRIE) alınmıştır. Bu karşılaştırma tablosu 22656 görüntüden oluşan sentetik veri seti (SYD) ile oluşturulmuş olup hem geleneksel görüntü iyileştirme hem de makine öğrenimi ve derin öğrenme temelli metotları incelemektedir. CRM, BIMEF, CegaHE, NPE ve WT metotlarının değerleri Wang vd. (2020) çalışmasında Tablo 8'den alınmıştır. 17 yöntem arasından en iyi 4 değer ve en kötü 1 değer (WT) alınmıştır.

Tablo 4.5’te SSTKPD 0.980 SSIM ve 36.34 PSNR değeriyle derin öğrenmenin kullanıldığı çalışmalardan bile daha yüksek skor elde ettiği görülmektedir. Diğer iki yöntem de hem SSIM hem de PSNR değerleri açısından yüksek değerlere sahip olduğu gözlemlenmektedir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada, gece sürüş güvenliğini artırmak amacıyla parlama etkisini azaltan ve yol detaylarının görünürlüğünü koruyan Ortalamaya Adaptif Üs Yasası Dönüşümü, Standart Sapma Tabanlı Kübik Polinom Dönüşümü ve İstatistik GÜDÜMLÜ Üstel Kontrast İyileştirme yöntemleri karşılaştırılmış ve değerlendirilmiştir. Çalışma kapsamında ayrıca, tamamen doğal gece sürüş koşullarını içeren 400 görüntülük bir veri seti oluşturularak literatüre katkı sağlanmıştır. Bu teknikler parlama bölgelerindeki parlaklığı sırasıyla %56, %24, ve %36 oranlarında azaltarak etkili bir baskılama performansı sergilemiştir. Standart Sapma Tabanlı Kübik Polinom Dönüşümü yöntemi ortalama 0.980 SSIM ve 36.34 dB PSNR değerleriyle görüntü kalitesini en iyi şekilde korurken, aynı zamanda farklı çözünürlüklerde 3 ms - 170 ms arasında işlem süreleriyle bütün çözünürlüklerde diğer yöntemlerden daha iyi sonuç elde etmiş ve gerçek zamanlı otomotiv görüş sistemlerine entegre edilebilirlik açısından da önemli bir avantaj sunmaktadır. Bu yöntem, parlama bölgelerindeki parlaklığı 163'ten ortalama 124 seviyesine düşürerek sürücülerin görüş konforunu artırırken, yol detaylarını da etkili şekilde korumayı başarmıştır.

Diğer iki yöntem olan Ortalamaya Adaptif Üs Yasası Dönüşümü ve İstatistik GÜDÜMLÜ Üstel Kontrast İyileştirme, benzer işlem sürelerine sahip olmakla birlikte, görüntü kalitesi metriklerinde ve dolayısıyla yol detaylarını korumada ikinci yönteme nazaran daha düşük performans sergilemişlerdir. Fakat parlaklığı daha iyi baskılamışlardır. Özellikle OAÜYD yöntemi, bazı görüntülerde SSIM değerlerini 0.63 seviyelerine kadar düşürmesi, bu yöntemin yol detaylarını korumada diğerlerine nazaran tutarsız sonuçlar verebileceğini göstermektedir. İstatistik GÜDÜMLÜ Üstel Kontrast İyileştirme yöntemi hem parlaklığı hem de kontrastı dengeleyen en iyi yöntem olmuştur. Ayrıca üç yöntem de hesaplama maliyeti açısından benzer işlem sürelerine sahip ve yeterli çözünürlüklerde 30 FPS'nin üzerinde olduğundan dolayı gerçek zamanlı otomotiv görüş sistemlerine entegre edilebilirler.

Gelecekte sis, yağmur vb. hava koşullarını da kapsayan, RGB dışındaki hiperspektral vb. kameralarla da desteklenen iyileştirmeler yapılabilir. Bunun yanı sıra elektrikli araçlarda giderek daha fazla alanı kaplayan kokpit ekranlarının da sürüş destek sistemlerine uygun olarak tasarlanması bu çözümleri yaygınlaştıracak ve gelişimini hızlandıracaktır. Önerilen yöntemlerin performanslarını donanım üzerinde test ederek, otonom araç sistemlerine entegrasyonu için optimizasyon yapılabilir.

Önerilen yöntemler, mevcut literatürdeki histogram eşitleme gibi geleneksel yöntemler veya derin öğrenme tabanlı tekniklerle aynı ortamlarda karşılaştırılarak etkinlik farkları değerlendirilebilir. Bu çalışma, gece sürüşü için görüntü iyileştirme alanında önemli bir adım atmış ve gelecekteki araştırmalar için sağlam bir temel sunmuştur.

KAYNAKLAR


- Ahire, A.A. (2014). Night vision system in BMW. *Int. Rev. Appl. Eng. Res.* 4(1), 1–10
- Bhalla, V. (2023). A Review on Neural Approaches in Image Processing Applications. *International Journal for Research in Applied Science & Engineering Technology*, 11(IV). <https://doi.org/10.22214/ijraset.2023.49851>
- Erdem, A. H., & Celebi, A. T. (2024, May). Enhancing Road Scene Visibility by Removing Sun and Headlight Glare in ADAS Camera Images with Image Fusion. In *2024 32nd Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- He, K., Sun, J., & Tang, X. (2012). Guided image filtering. *IEEE transactions on pattern analysis and machine intelligence*, 35(6), 1397-1409.
- Hogervorst, M. A., & Toet, A. (2010). Fast natural color mapping for night-time imagery. *Information Fusion*, 11(2), 69-77.
- Jang, I. S., Park, K. H., & Ha, Y. H. (2009). Color correction by estimation of dominant chromaticity in multi-scaled retinex. *Journal of imaging science and Technology*, 53(5), 50502-11.
- Jenipher, S.A., Aswin, P., Gowsalya, S., Devi, C.M., Baskaran, D. (2019). Automated headlight intensity controller and speed control in vehicles. *J. Netw. Sec.* 7(2), 1–5.
- Jiang, X. (2014). *Introduction to meteorology* [Lecture slides]. California Institute of Technology. <https://web.gps.caltech.edu/~xun/course/GEOL1350/Lecture20.pdf>
- Jung, C., Yang, Q., Sun, T., Fu, Q., & Song, H. (2017). Low light image enhancement with dual-tree complex wavelet transform. *Journal of Visual Communication and Image Representation*, 42, 28-36.
- Kuang, H., Chen, L., Gu, F., Chen, J., Chan, L., & Yan, H. (2016). Combining region-of-interest extraction and image enhancement for nighttime vehicle detection. *IEEE Intelligent systems*, 31(3), 57-65.
- Lin, H., & Shi, Z. (2014). Multi-scale retinex improvement for nighttime image enhancement. *optik*, 125(24), 7143-7148.
- Li, H., Chen, J., Zheng, A., Wu, Y., & Luo, Y. (2024). Day-Night Cross-domain Vehicle Re-identification. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 12626-12635).
- Lin, S. C. F., Wong, C. Y., Rahman, M. A., Jiang, G., Liu, S., Kwok, N., ... & Wu, T. (2015). Image enhancement using the averaging histogram equalization (AVHEQ) approach for contrast improvement and brightness preservation. *Computers & Electrical Engineering*, 46, 356-370.
- Lyu, X., Wang, N., & Gao, J. (2024). Single-Frame Difference-Based Image Fusion Glare-Resistant Detection System in Green Energy Vehicles. *IEEE Access*.
- Mandal, G., Bhattacharya, D., & De, P. (2021). Real-time automotive night-vision system for drivers to inhibit headlight glare of the oncoming vehicles and enhance road visibility. *Journal of Real-Time Image Processing*, 18(6), 2193-2209.

- Meyer, B., Grogorick, S., Vollrath, M., & Magnor, M. (2016). Simulating visual contrast reduction during nighttime glare situations on conventional displays. *ACM Transactions on Applied Perception (TAP)*, 14(1), 1-20.
- Pamane, K., & Chaisricharoen, R. (2013, September). Vision restoration of dangerous head light glare affected scenario. In *2013 13th International Symposium on Communications and Information Technologies (ISCIT)* (pp. 733-736). IEEE.
- Patil, M. B., & Phakade, S. V. (2019). Adaptive Head Light System using Image Processing. *International Journal of Electronics Engineering (IJITEE)*, 11(1).
- Pharadornpanitchakul, S., Duangchit, A., & Chaisricharoen, R. (2014, March). Enhanced danger detection of headlight through vision estimation and vector magnitude. In *The 4th Joint International Conference on Information and Communication Technology, Electronic and Electrical Engineering (JICTEE)* (pp. 1-4). IEEE.
- Qi, Y., Yang, Z., Sun, W., Lou, M., Lian, J., Zhao, W., ... & Ma, Y. (2021). A comprehensive overview of image enhancement techniques. *Archives of Computational Methods in Engineering*, 1-25.
- Qian, X., Wang, Y., & Wang, B. (2012). Fast color contrast enhancement method for color night vision. *Infrared Physics & Technology*, 55(1), 122-129.
- Sathe, A., Roshankhede, P., Golar, P., Chitatar, C. (2018). Reducing headlight intensity to improve street visibility. *Int. J. Adv. Res. Ideas Innov. Technol.* 4(2), 1682–1686.
- Shi, Z., Zhu, M. M., Guo, B., Zhao, M., & Zhang, C. (2018). Nighttime low illumination image enhancement with single image using bright/dark channel prior. *EURASIP Journal on Image and Video Processing*, 2018, 1-15.
- Tang, C., Wang, Y., Feng, H., Xu, Z., Li, Q., & Chen, Y. (2019). Low-light image enhancement with strong light weakening and bright halo suppressing. *IET Image Processing*, 13(3), 537-542.
- Tang, H., Zhu, H., Fei, L., Wang, T., Cao, Y., & Xie, C. (2023, February). Low-illumination image enhancement based on deep learning techniques: A brief review. In *Photonics (Vol. 10, No. 2, p. 198)*. MDPI.
- Tao, L., Zhu, C., Xiang, G., Li, Y., Jia, H., & Xie, X. (2017, December). LLCNN: A convolutional neural network for low-light image enhancement. In *2017 IEEE Visual Communications and Image Processing (VCIP)* (pp. 1-4). IEEE.
- Tsagaris, V., & Anastassopoulos, V. (2005). Fusion of visible and infrared imagery for night color vision. *Displays*, 26(4-5), 191-196.
- Turan, B. (2021). A image enhancement method for night-way images. *Balkan Journal of Electrical and Computer Engineering*, 9(1), 8-16.
- Wang, W., Wu, X., Yuan, X., & Gao, Z. (2020). An experiment-based review of low-light image enhancement methods. *Ieee Access*, 8, 87884-87917.
- Xu, J., Chen, Z., Ni, X., & Lu, Z. (2007). A new method of glare protection on highway real-time monitoring during nighttime. In *27th International Congress on High-Speed Photography and Photonics (Vol. 6279, pp. 1356-1362)*. SPIE.


- Xu, Y. J., Wu, Y. Y., Yuan, W. L., & Jiang, L. C. (2022, December). Realization of Anti-glare Algorithm Based on Stagnant Water Reflection of Automobile Headlights on Rainy Day. *In 2022 10th International Conference on Information Systems and Computing Technology (ISCTech)* (pp. 696-701). IEEE.
- Yin, S., Cao, L., Ling, Y., & Jin, G. (2010). One color contrast enhanced infrared and visible image fusion method. *Infrared Physics & Technology*, 53(2), 146-150.

EKLER


EK 1. Ortalamaya Adaptif Üs Yasası Dönüşümü Sonuçları



EK 2. Standart Sapma Tabanlı Kübik Polinom Dönüşümü Sonuçları



EK 3. İstatistik G d ml   stel Kontrast İyileřtirme Sonu ları



ÖZ GEÇMİŞ

Adem BAKIRCI, Kara Harp Okulu Sistem Mühendisliği bölümünden 2009 yılında ve Anadolu Üniversitesi Uluslararası İlişkiler (İngilizce) bölümünden 2022 yılında mezun oldu. 2022 yılında OMÜ LEE İstatistik Ana Bilim Dalı Veri Bilimi Yüksek Lisans programına girdi. Bir özel şirkette Python ve Yapay Zeka Eğitmeni olarak görev yapan Adem BAKIRCI, iyi derecede İngilizce bilmektedir (YDS:84).

İletişim Bilgileri

ORCID ID : 0009-0006-1128-4418

Yayınlar:

Bakırcı, A., & Ergün, E. (2025). Adaptive brightness control and detail enhancement for nighttime driving safety. In **Proceedings of the Cumhuriyet 14th International Conference on Applied Sciences** (pp. 209–220). ISBN: 978-625-5962-62-1. https://www.cumhuriyetkongresi.org/_files/ugd/797a84_88612a23720b43e887c2afe13ea0f847.pdf