T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DÜŞÜK AYDINLIKLI GÖRÜNTÜ İYİLEŞTİRMEDE DİKKAT MEKANİZMALARININ ETKİLERİ

Mine ONAT

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ŞANLIURFA
2023

İÇİNDEKİLER

Sayfa No

ÖZET ..... İ

ABSTRACT ..... İİ

TEŞEKKÜR ..... İİİ

ŞEKİLLER DİZİNİ ..... İV

ÇİZELGELER DİZİNİ V

SİMGELER ve KISALTMALAR DİZİNİ ..... Vİ

1. GİRİŞ 1

1.1. ÇALIŞMANIN İÇERİĞİ 2

2. ÖNCEKİ ÇALIŞMALAR 4

3. MATERYAL ve YÖNTEM 13

3.1. MATERYAL 13
3.1.1. Veri kümesi 13
3.2. YÖNTEM 14
3.2.1. Evrişimli sinir ağları 14
3.2.2. SSIENet 16
3.2.3. Dikkat mekanizmaları 16
3.2.3.1. Sıkma ve uyarma dikkat ağı 19
3.2.3.2. Kanal dikkat ağı 19
3.2.3.3. Etkili kanal dikkat ağı 20
3.2.3.4. Darboğaz dikkat ağı 23
3.2.3.5. Koordinat dikkat ağı 25
3.2.3.6. Uzamsal ve kanal sıkma ve uyarma dikkat ağı 27
3.2.4. Değerlendirme ölçütleri *27*

4. ARAŞTIRMA BULGULARI ve TARTIŞMA 31

4.1. ÖNERİLEN YÖNTEMİN SAYISAL KARŞILAŞTIRILMASI 31
4.2. ÖNERİLEN YÖNTEMİN GÖRSEL KARŞILAŞTIRILMASI 33
4.3. TARTIŞMA 42

5. SONUÇLAR ve ÖNERİLER 44

KAYNAKLAR 46

ÖZET

Yüksek Lisans Tezi

DÜŞÜK AYDINLIKLI GÖRÜNTÜ İYİLEŞTİRMEDE DİKKAT MEKANİZMLARININ ETKİLERİ

Mine ONAT

Harran Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Serdar ÇİFTÇİ
Yıl: 2023, Sayfa: 50

Bilgisayarlı görü çalışmalarının başarısını önemli ölçüde artıracak olan girdi görüntülerinin netliği, kameraların doğal sahnelerin doyum noktalarına erişemediklerinden ötürü yakalanamamaktadır. Fotoğraf makinelerinin pozlama süreleri kısa tutulduğunda yakaladıkları sahnelerin karanlık olması gibi, uzun tutulduğunda ise elde edilen sahnelerin fazla aydınlıktan dolayı görüntü netliği istenilen yüksek dinamik aralığa ulaşamamaktadır. Pozlama süresinin kısa tutulmasıyla elde edilen karanlık sahne hem net değildir hem de istenmeyen gürültülere sahiptir. Pozlama süresi uzun tutularak elde edilen fazla aydınlık sahne bulanıklaşırken aynı zaman da fotoğraf çekilirken sürenin uzun tutulmasıyla eldeki titremeden kaynaklı problemleri de beraberin de getirir. Fotoğraf makinelerinin sınırlı dinamik aralık problemini çözmek için düşük ışıklı görüntü iyileştirme algoritmaları kullanılır. Bu tez çalışmasının temel amacı, düşük aydınlıklı görüntüleri iyileştirmek için dikkat mekanizmalarının etkilerini ölçmektir. Bu amaçla literatürde başarılı sonuç sergileyen SSIENET yöntemi baz alınarak farklı dikkat mekanizmalarının kullanıldığı düşük aydınlıklı görüntü iyileştirme yöntemi önerilmiştir. Literatürde var olan düşük aydınlıklı görüntü iyileştirme yöntemlerine farklı dikkat mekanizmaları dahil edildiğinde daha başarılı sonuçlar elde edildiği gözlemlenmiştir.

ANAHTAR KELİMELER: Düşük aydınlıklı görüntü iyileştirme, dikkat mekanizmaları, derin öğrenme.

ABSTRACT

MSc Thesis

THE EFFECTS OF ATTENTION MECHANISMS ON LOW LIGHT IMAGE ENHANCEMENT

Mine ONAT

Harran University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Serdar ÇİFTÇİ
Year: 2023, Page No: 50

The clarity of the input images, which will significantly increase the success of computer vision studies, cannot be captured because the cameras cannot access the deseired points of natural scenes. Just as the scenes they capture when the exposure times of the cameras are kept short are dark, when they are kept long, the image clarity cannot reach the desired high dynamic range due to too much light. The dark scene obtained by keeping the exposure time short is both unclear and has unwanted noisy. The too bright scene obtained by keeping the exposure time long becomes problems caused by shaking in the hand. Low-light image enhancement algorithms are used to solve the problem of limited dynamic range of cameras. The main purpose of this thesis is to measure the effects of attention mechanisms to improve low-light images. For this purpose, a low-light image enhancement method using different attention mechanisms has been proposed based on the SSIENET method, which has shown successful results in the literature. It has been observed that more successful results are obtained when different attention mechanisms are included in the low-light image enhancement study existing in the literature.

KEY WORDS: Low light image enhancement, attention mechanisms, deep learning.

TEŞEKKÜR

Lisansüstü eğitimim boyunca bilgi ve birikimleriyle bana destek olan değerli hocam Dr. Öğr. Üyesi Serdar ÇİFTÇİ'ye, sadece akademik alanda değil hayatın her kademesinde bana sürekli destek olan, zor zamanlarımda sabır gösterip her daim inançları ile güç veren aileme ve eşim Osman ONAT'a teşekkür ederim.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. Düşük Aydınlıklı Görüntüler……. 1

Şekil 3.1. Veri setinde yer alan görüntüler (a)Düşük aydınlıklı (b)Normal aydınlıklı……..……. 13

Şekil 3.2. Baz alınan SSIENet iskelet yapı……..……. 17

Şekil 3.3. SSIENet mimarisinden uyarlanmış önerilen mimari..……. 18

Şekil 3.4. Sıkma ve uyarma ağı……..…….. 19

Şekil 3.5. Kanal dikkat ağı……..……. 20

Şekil 3.6. Etkili kanal dikkat ağı……..……. 23

Şekil 3.7. Darboğaz dikkat ağı……...…..……. 25

Şekil 3.8. Koordinat dikkat ağı……..……..…….. 26

Şekil 3.9. Uzamsal ve kanal sıkma ve uyarma……..…..…….. 27

Şekil 4.1. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans……..... 36

Şekil 4.2. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans……..... 37

Şekil 4.3. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans……..... 38

Şekil 4.4. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans……..... 39

Şekil 4.5. Yukarıdan aşağıya doğru sırasıyla Düşük aydınlıklı giriş, SSIENet, Sıkma ve uyarma, Etkili kanal, Uzamsal ve Kanal Sıkma ve Uyarma, Kanal, Darboğaz, Koordinat ve Referans sonuçları .....……..... 40

Şekil 4.6. Cep telefonuyla çekilmiş görüntünün test sonuçları (a)Girdi görüntü (b)Histogram Eşitleme (c)SSIENet (d)Sıkma ve Uyarma (e)Etkili Kanal (f)Uzamsal ve Kanal Sıkma ve Uyarma (g)Kanal (h)Darboğaz (ı)Koordinat……..... 41

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3.1. Farklı katmanlara eklenen dikkat mekanizmalarının PSNR sonuçları.....…… 18

Çizelge 4.1. En iyi sonucu veren dikkat mekanizmalarının katman sıralama yapısı…….…... 32

Çizelge 4.2. Farklı dikkat mekanizmalarının, Histogram eşitlemenin ve SSIENet görüntülerinin PSNR, SSIM, LRI ve NSER performans kıyaslaması …….……..…..... 33

SİMGELER VE KISALTMALAR DİZİNİ

BAM	Bottleneck Attention Module (Darboğaz Dikkat Modülü)
Cb	Mavi Renk Farkı
CDF	Kümülatif Dağılım Fonksiyonu
CNN	Convolutional Neural Network (Evrişimli Sinir Ağı)
Cr	Kırmızı Renk Farkı
ECA	Efficient Channel Attention (Etkili Kanal Dikkat)
GHE	Global Histogram Eşitleme
HE	Histogram Eşitleme
LHE	Lokal Histogram Eşitleme
LOL	Low Light Paired Dataset (Düşük Aydınlıklı Çift Veri kümesi)
MSE	Peak Signal-to-Noise Ratio (Tepe Sinyal-Gürültü Oranı)
PSNR	Mean Squared Error
SCSE	Spatial and Channel Squeeze and Excitation (Uzamsal ve Kanal Sıkma ve Uyarma)
SENet	Squeeze and Excitation Network (Sıkma ve Uyarma Ağı)
SSIENet	Self-supervised Image Enhancement Network
SSIM	Structural Similarity Index Metric (Yapısal Benzerlik İndeks Metriği)
Y	Luma (Parlaklık)

1. GİRİŞ

Düşük aydınlık, aydınlatmanın normal standartlara uymadığı çevresel koşulları ifade eder (Kim ve ark., 2014). Düşük aydınlıklı ortamı tanımlayan standart bir değer mevcut olmadığından her görüntü sensörü üreticinin kendi standartları vardır; örneğin Hikvision genellikle düşük ışıklı ortamları, karanlık seviye (0,01 Lux - 0,1 Lux), ay ışığı seviye (0.001 Lux - 0.01 Lux) ve yıldız ışığı seviyesi (daha az 0.001 Lüks) olarak nitelendirir (Wang ve ark., 2020). Yetersiz veya düzgün olmayan ışık altında alınan görüntüler, düşük parlaklık, zayıf kontrast, bulanıklaşmış yerel detaylar, zayıf renk kalitesi, ışıkta ani değişiklikler ve hatta çoğu zamanda çok fazla gürültü sergilemektedir (Katırcıoğlu, 2021). Geceleri veya gölgede, yavaş deklanşör hızı, düşük diyafram parlaklığı ve görüntü sensörü hassasiyeti gibi bazı fiziksel kısıtlamalar nedeniyle karanlık sonuçlar elde edilebilmektedir (Kim ve ark., 2022). Düşük aydınlık koşullarında çekilen görüntüler oldukça düşük signal-to-noise-ratio (SNR) değerlerine sahip olduklarından gürültülerin oldukça yoğun olduğu ve görüntü sinyallerinin üzerinde baskın olabileceği anlamına gelmektedir (Li ve ark., 2018). Kamera sensörlerine ulaşan yetersiz aydınlık, sahne sinyalinin sistem gürültüsünden etkilenmesine neden olmaktadır (Yang ve ark., 2020). Bu çalışmada kullanılan bazı düşük aydınlıklı görüntüler Şekil 1.1.'de verilmiştir.



Şekil 1. 1. Düşük Aydınlıklı Görüntüler (Wei ve ark., 2018)

Düşük aydınlıklı görüntüleri elde etmenin bir nedeni çevre şartları iken diğer nedeni ise kullanılan donanım cihazlarıdır. Bu nedenle düşük aydınlıklı görüntüleri iyileştirmek için hem donanımsal hem de yazılımsal geliştirmeler yapılmıştır. Düşük aydınlık kameraları, yüksek performanslı şarj bağlantılı cihaz (CCD) ya da tamamlayıcı metal oksit yarı iletken (CMOS) teknoloji, profesyonel düşük aydınlık devreleri ve düşük aydınlık seviye görüntülerinin kalitesini geliştirmek için temel bileşen olarak filtreler kullanırlar (Yuantao ve ark., 2018). Sony, Photonis, SiOnyx ve Texas Instruments (TI) gibi bazı şirketler tarafından üretilen profesyonel düşük

aydınlıklı kameralar yüksek fiyatlarından ötürü günlük hayatta kullanılmamaktadır (Wang ve ark., 2020). Bu nedenle görüntü cihazlarının performansını geliştirmek için diğer alternatif yol olan yazılımsal olarak düşük aydınlıklı geliştirme algoritmaları yapılmaktadır.

Düşük aydınlıklı görüntü iyileştirmenin amacı görüntünün genel ve lokal kontrastını geliştirme, görsel etkiyi iyileştirme, bilgisayar işleme ya da insan görmesi için görüntüyü daha iyi bir forma dönüştürmedir (Hao ve ark., 2018). Net görüntüler üretmek için düşük aydınlıklı görüntüleri kullanılabilir yapmak gerekmektedir. Düşük aydınlıklı görüntü geliştirme, insanların görsel algısıyla uyumlu olmasının yanı sıra, bu tür görüntülerin bilgisayarla görme ekipmanı tarafından daha rahat analiz edilmesine ve işlenmesine olanak tanır (Sun ve ark., 2018). İlgili çalışmalar şehir trafik izleme, dış mekan video elde etme, uydu uzaktan algılama, askeri havacılık araştırması alanlarına uygulanabilir ve su altı görüntü analizi, bulanık görüntü netliği gibi çalışma konularına referans olarak kullanılabilmektedir (Lim ve ark., 2017). Ayrıca görüntü işleme alanında önemli bir araştırma branşı olan düşük aydınlıklı görüntü iyileştirme, son yıllarda geniş uygulama alanları ve disiplinler arası araştırma odağına sahiptir (Pei ve ark., 2017).

1.1. Çalışmanın İçeriği

Bu çalışma SSIENET (Zhang ve ark., 2020) mimarisi üzerine düşük aydınlıklı görüntü iyileştirme çalışmasını derin öğrenme yöntemlerinden olan dikkat mekanizmalarıyla iyileştirmeyi ve aynı zamanda farklı dikkat mekanizmalarının da düşük aydınlıklı görüntü iyileştirme üzerindeki performanslarını kıyaslamayı amaçlamaktadır. Bu çalışmada, LOL (Wei ve ark., 2018) veri seti kullanılarak Google Colab ortamında darboğaz dikkat (Park ve ark., 2018), koordinat dikkat (Hou ve ark., 2021), kanal dikkat (Bastidas ve ark., 2019), etkili kanal dikkat (Wang ve ark., 2020), sıkma ve uyarma dikkat (Hu ve ark., 2018), uzamsal ve kanal sıkma ve uyarma dikkat (Roy ve ark., 2018) mekanizmalarıyla ayrı ayrı model eğitimleri yapılıp test işlemleri gerçekleştirilmiştir. Python programlama dilinin Tensorflow, open-cv, numpy, scikit-learn kütüphaneleriyle iyileştirme yapılmıştır.

Önceki çalışmalar başlığı altında, literatürde yer alan düşük ışıklı görüntü iyileştirme ile ilgili daha önce yapılmış çalışmalara yer verilmiştir. Materyal ve yöntem kısmında tez çalışmasında kullanılan veri seti, evrişimsel sinir ağı ve dikkat mekanizmaları algoritmaları bilgileri ve bunlara ait eğitim ve test sonuçlarıyla elde edilen değerlendirme ölçütleriyle ilgili bilgiler verilmiştir.

Araştırma bulguları ve tartışma kısmında kullanılan modellerin değerlendirme ve birbirleriyle olan kıyaslama sonuçları sayısal ve görsel şekilde detaylandırılmıştır. Bu bölümde ayrıca kullanılan dikkat mekanizmaları birbirleriyle de kıyaslanması gösterilmiştir. Sonuçlar ve öneriler bölümünde ise önerilen yaklaşımın literatüre olan katkısına yer verilmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Düşük aydınlıklı görüntülerin iyileştirilmesi başka alanlardaki çalışmalar için de önemli bir problemdir. Görüntüler karanlık ve az pozlanmış oldukları için hem bilgi çıkarmak hem de gürültüyü gidermek oldukça zordur. Hem görüntü işleme hem de derin öğrenme yöntemleriyle birçok araştırmacı düşük aydınlıklı görüntü iyileştirme amacıyla çeşitli yöntemler kullanmışlardır.

Görüntü kalitesini geliştirmeyi amaçlayan düşük aydınlıklı görüntü iyileştirme çalışmaları aynı zamanda kontrast geliştirme ve pozlama düzeltme de olmak üzere üç farklı isimle adlandırılmaktadırlar. Düşük aydınlıklı görüntü geliştirme algoritmalarına, Gri dönüştürme metotları, Histogram eşitleme, Retineks teorisi, Frekans-alan metotları, Görüntü birleştirme metotları, Buğu giderme metotları ve Makine öğrenimi metotları örnek olarak verilebilir.

Gri dönüşüm yöntemi, genellikle haritalama tabanlı yaklaşım olarak adlandırılan matematiksel bir fonksiyon aracılığıyla ayrı ayrı tekil piksellerin gri değerlerini diğer gri değerlere dönüştürme ilkesine dayanan uzamsal-alan geliştirme algoritmasıdır (Xu ve ark., 2014). Bu yöntem piksellerin gri değerlerinin dinamik aralığını ve dağılımını değiştirerek görüntü geliştirir (Hao ve ark., 2017). Bu metotlar doğrusal ve doğrusal olmayan dönüşüm alt sınıflarından oluşurlar.

Doğrusal dönüşüm, giriş görüntüsünün gri değerlerinin doğrusal fonksiyonu şeklinde dönüşümünü ifade eder. Doğrusal görüntü iyileştirme ilkesinin uygulanması basit ve hızlıdır, ancak etki tatmin edici değildir, bazı görüntü ayrıntıları genellikle düzensiz görüntü iyileştirme nedeniyle kaybolur (Wang ve ark., 2020).

Feng ve ark., (2017), karanlık bölgelerde gizlenen görüntüleme gürültü sorunu ele almak için, Retinex teorisine dayalı model tasarlamışlardır. Yerel görüntü yapısından haberdar olması için, aydınlatma haritasını kendinden kılavuzlu filtreleme yöntemiyle iyileştirmişlerdir.

Doğrusal olmayan gri dönüşümün temel fikri, bir görüntünün gri değerlerini

dönüştürmek için doğrusal olmayan bir fonksiyon kullanmaktır (Wang ve ark., 2018). Sık kullanılan doğrusal olmayan dönüşüm fonksiyonları logaritmik fonksiyonları, gama fonksiyonlarını ve diğer çeşitli gelişmiş fonksiyonları içerir (Srinivas ve ark., 2020). Logaritmik dönüştürme fonksiyonu, çıkış görüntüsündeki her pikselin değeri ile giriş görüntüsündeki karşılık gelen pikselin değeri arasında logaritmik bir ilişki olduğunu gösterir (Wang ve ark., 2020). Bu dönüştürme türü aşırı karanlık bir görüntü için uygundur, çünkü piksellerin dinamik aralığını daha yüksek gri değerlerle sıkıştırırken görüntünün düşük gri değerlerini genişletebilir (Panetta ve ark., 2010). Gri dönüşüm gri ilgi alanlarını vurgulayabilir ve basit uygulama ve yüksek hız avantajlarına sahip olmakla birlikte, bu tür yöntemler bir görüntünün genel gri dağılımını dikkate almaz; Sonuç olarak, geliştirme yetenekleri sınırlıdır ve uygulanabilirlikleri zayıftır (Wang ve ark., 2020).

Srinivas ve ark. (2020), görsel kaliteyi iyileştirmek ve bozulmaları azaltmak için, basit ve hesaplama açısından verimli bir düşük ışıkta görüntü geliştirme çerçevesi tasarlamışlardır. Bunu başarmak için, uyarlanabilir bir sigmoid transfer fonksiyonu (ASTF) kullanmışlardır. Sinir ağlarının sigmoid aktivasyon fonksiyonundan türetmişlerdir. ASTF'yi bir Laplace operatörü ile birleştirerek renkli ve kontrastı artırılmış görüntüler elde etmişlerdir.

Histogram Eşitleme; bir görüntüdeki renklerin belli bir yere dağılmasından kaynaklı bozukluğu, dengeli bir şekilde dağıtarak gideren bir görüntü işleme tekniğidir. Bir görüntünün piksel değerleri olası tüm gri düzeylerine eşit olarak dağıtılmışsa, görüntü yüksek kontrast ve geniş bir dinamik aralık gösterir. Bu özelliğe dayanarak, HE (Histogram Eşitleme) algoritması, çıktı gri seviyelerini, tekdüze bir dağılıma karşılık gelen bir olasılık yoğunluğu fonksiyonuna sahip olacak şekilde ayarlamak için kümülatif dağılım fonksiyonunu (CDF) kullanır. Standart Histogram eşitleme algoritmasının prensibi basittir ve gerçek zamanlı olarak yürütülebilir. Ancak, geliştirilmiş görüntünün parlaklığı eşit olmaz ve gri düzeyde birleştirme nedeniyle bazı ayrıntılar kaybolabilir (Wang ve ark., 2020). Hesaplamada dikkate alınan bölgelere bağlı olarak, HE yöntemleri global histogram eşitleme (GHE) ve yerel histogram eşitleme (LHE) olarak ikiye ayrılabilir (Li ve ark., 2014).

GHE modelinin nispeten az hesaplama ve yüksek verimlilik gibi çeşitli avantajları vardır ve özellikle genel olarak daha koyu veya daha parlak görüntülerin geliştirilmesi için uygundur (Tian ve ark., 2015). Ancak, tüm görüntünün gri değerlerine dayalı istatistiksel işlemler yürüten küresel bir algoritmanın, her yerel bölge için en uygun kurtarılan değerleri elde etmesi zordur. Böyle bir algoritma, giriş görüntüsünün yerel parlaklık özelliklerine uyum sağlayamaz ve sonuç olarak, işlemden sonra görüntüdeki derinlik hissi azalır.

Bu sorunu çözmek için, birçok bilim adamı bunun yerine bir LHE algoritmasının kullanılması gerektiğini öne sürmüş ve bu algoritmalar bu nedenle geniş çapta uygulamaya konmuştur. LHE'nin temel fikri, HE işlemini bir görüntünün çeşitli yerel alanlarına ayrı ayrı uygulamaktır. Orijinal görüntü uzamsal olarak birden fazla alt bloğa bölünür ve istenen geliştirme efektini elde etmek için görüntünün yerel bilgilerini uyarlanabilir şekilde geliştirmek için eşitleme her alt blokta ayrı ayrı gerçekleştirilir.

Wadud ve ark. (2007), yaptıkları çalışmada görüntü histogramını yerel minimumlara göre bölümlere ayırıp bu bölümlerin her biri için belirli gri seviye aralıklar atamışlardır. Bu bölümlerden herhangi birinin baskın olabilmesi ihtimaline karşın testler gerçekleştirerek başarılı bir şekilde kontrastı artırmışlardır.

1971 yılında Edwin Land tarafından önerilen Retineks teorisi bir görüntü geliştirme yöntemidir. Teoriye ismini veren Retineks, retina ve korteks kelimelerinin sentezlenmesiyle türetilmiştir. Retineks teorisine göre, insan görsel sistemi görsel bilgi iletimi boyunca spesifik bir yolda bilgi işler, bu nedenle, ışık kaynağının yoğunluğu ve ışığın düzensizliği gibi bir dizi belirsiz faktörü ortadan kaldırır (Wang ve ark., 2020). Sonuç olarak, yalnızca yansıma katsayısı gibi nesnenin temel özelliklerini yansıtan bilgiler korunur (Park ve ark., 2017).

Retineks teorisi görüntüyü aydınlatma ve yansıma bileşenlerine ayırarak görüntünün detaylı analiz edilmesini sağlar. Aydınlatma-yansıma modeline dayanarak bir görüntü yansıtma bileşeni ve aydınlatma bileşeninin ürünü olarak açıklanabilir (Lee ve ark., 2015). (x,y) herhangi bir pikselin yatay ve düşey koordinatlarını temsil etmekle birlikte, I(x,y) görüntüsü aşağıdaki gibi tanımlanabilir:

$$I(x,y) = L(x,y).R(x,y) \quad (2.1)$$

Burada L(x,y) görüntünün aydınlatma bileşenini, R(x,y) ise görüntünün yansıtma bileşenini temsil etmektedir. L(x,y) görüntünün dinamik aralığını belirlerken, R(x,y) görüntünün doğal doğasını belirler (Wang ve ark., 2020). Retineks teorisine göre L(x,y) I(x,y)'den tahmin edilebilirse, ardından yansıma bileşeni toplam ışık miktarından ayrılabilir ve görüntüdeki aydınlanma bileşeninin etkisi görüntü geliştirmek için azaltılabilir (Liu ve ark., 2016). Retineks algoritması renk sabitliği, geniş dinamik aralık sıkıştırma ve yüksek renk doğruluğu gibi keskinleştirme kabiliyetine sahiptir (Wang ve ark., 2020).

Guo ve ark. (2016), çalışmalarında retineks teorisi ile görüntüyü yansıtma ve aydınlatma bileşenlerine ayırmışlardır. Aydınlatma haritasına tahmin yaparak başarılı gelişmeler sağlamışlardır.

Hao ve ark. (2020), düşük aydınlıklı tek bir giriş görüntüsündeki sınırlı bilgiden dolayı retineks yöntemiyle girdi sayısını arttırmışlardır. Yansıtma ve aydınlatma bileşenlerinden oluşan retineksin ilk olarak sadece aydınlatma bileşenini kullanmışlar, ardından yansıtma bileşenini de dahil etmişlerdir. Ayrıca giriş görüntüsünün karanlık olmasından kaynaklı olan gürültüyüde ekleyerek başarılı bir çalışma ortaya koymuşlardır.

Çok ölçekli görüntü analizi teknolojisinin gelişmesiyle birlikte, görüntü geliştirme algoritmaları üzerine araştırmalar uzamsal alandan frekans alana genişletildi (Wang ve ark., 2020). Görüntü iyileştirme metotları Fourier analizi aracılığıyla filtrelemek için uzamsal alanındaki görüntüyü frekans alanına dönüştürmeye ve sonra final görüntüyü tekrar geri uzamsal alana dönüştürmeye dayanmaktadır (Wang ve ark., 2020). Frekans-alan metotları Homomorphic filtering(HF) ve Wavelet Transform (WT) metotları kapsamaktadır.

Wang ve ark. (2020), düşük aydınlıklı görüntülerin gözlemlenebilirliğini geliştirmek için, alt örneklemesiz shearlet dönüşümüne (NSST) dayalı bir düşük aydınlıklı görüntü geliştirme algoritması sunmulardır. Önerilen algoritma, eşzamanlı olarak kontrast iyileştirme, gürültü bastırma ve belirli yön ayrıntılarının geliştirilmesini sağlayabilmektedir.

Düşük aydınlıklı görüntü iyileştirme metotlarından bir diğeri görüntü füzyon teknikleridir. Bu yöntemlerde aynı sahneden birden fazla görüntü çıkarmak için farklı sensörler yardımıyla yapılabilirken farklı görüntüleme yöntemleriyle de ek görüntüler elde edilebilmektedir. Son olarak, yüksek kaliteli bir görüntü sentezlemek için her görüntüden mümkün olduğunca çok yararlı bilgi çıkarılır, böylece görüntü bilgilerinin kullanım oranı iyileştirilir. Sentezlenen görüntü, sahneyi kapsamlı bir şekilde tanımlamak için orijinal görüntülerden çok düzeyli bilgileri yansıtabilir, böylece mevcut görüntü bilgilerinin hem insan gözlemcilerinin hem de bilgisayarlı görme sistemlerinin gereksinimlerini daha iyi karşılamasını sağlar (Wang ve ark., 2020).

Ying ve ark. (2017), tek pozlama oranının tüm piksellere aynı başarıyı getirmediği kanısına varmışlardır. Bu nedenle pozlama oranı haritası geliştirerek başarılı bir düşük aydınlıklı geliştirme çalışması ortaya koymuşlardır.

Cai ve ark. (2018), en küçük kareler yöntemiyle ayrıştırma yapıp girdi görüntüleri çoğaltmışlardır. Yansıtma bileşenini evrişimlerden, aydınlatma bileşenini ise U-Net mimarilerinden geçirip birleştirerek düşük aydınlıklı görüntü geliştirmeye katkıda bulunmuşlardır.

Shen ve ark. (2017), girdi görüntülerini çok ölçekli logaritmik dönüşümle çoğaltmışlardır. Atlamalı bağlantılı evrişim bloklarıyla başarılı bir çalışma oluşturmuşlardır.

Zhu ve ark. (2020), girdiyi iki farklı pozlama oranı ile çarparak girdileri çoğaltmışlardır. Her iki girdiyi ayrı ayı U-Net mimarilerinden geçirip her katmanda ortalama ve maksimum füzyon bloklarından geçirmişlerdir. Ardından U-Net sonrası birleşim yapmışlardır. Bu birleşim çıktısı girdi olarak tekrar kenar belirleme algoritmasından geçirip U-Net mimarisiyle yüksek aydınlıklı görüntü üretmişlerdir.

Lu ve ark. (2020), -1 ve -2 pozlama değerlerinde ürettiği girdilerden -2 pozlama değerindeki girdilerden gürültü giderme yapmışlardır. U-Net ve Dikkat mimarilerinden geçirerek yüksek aydınlıklı görüntü sunmuşlardır.

Liang ve ark. (2022), yapıcı öğrenme yöntemleri sayesinde veri setine bağımlılığı kaldırmışlardır. Az ve çok pozlanmış diye nitelendirdikleri negatif girdilerini ve normal pozlanmış olan pozitif girdilerini özellik ağlarından geçirmişlerdir. Özellik çıkarımının ardından sırasıyla görüntü geliştirme ve anlamsal bölütleme ağlarından geçirerek çıktılar için ayrı ayrı kayıp fonksiyonları uygulayarak başarılı bir çalışma ortaya koymuşlardır.

Buğu giderme yöntemi, düşük ışıkta ters çevrilmiş bir görüntünün koyu birincil renk versiyonunun ve buğulu bir görüntünün koyu ana renk versiyonunun istatistiksel analizine dayanır (Wang ve ark., 2020). Algoritmanın ana fikri, karanlık bir ortamda yakalanan bir RGB görüntüsü ters çevrildiğinde, görsel etkinin buğulu bir ortamda elde edilen gündüz görüntüsüne benzer olmasıdır. Bu nedenle, ters çevrilmiş düşük ışıklı görüntüyü işlemek için daha önce karanlık bir kanala dayanan bir söndürme algoritması kullanılabilir. Ardından, düşük ışıkta gelişmiş bir görüntü elde etmek için görüntü tekrar ters çevrilebilir (Wang ve ark., 2020).

Bu geliştirme yöntemi, düşük ışıklı görüntünün özelliklerini analiz ederek ve bunları buğulu bir görüntü bozulma modeliyle modelleyerek görüntü parlaklığını büyük ölçüde artırır ve görüntünün görsel ayrıntılarını geliştirir.

Li ve ark. (2015), düşük aydınlıklı görüntüyü süper piksellere bölmüşlerdir ve yerel standart sapma ile yerel gradyanlar arasındaki oranı, her bir süper pikselin gürültü-doku seviyesini tahmin etmek için kullanmışlardır. Daha sonra görüntüyü birinci dereceden diferansiyeli ile başka bir ayrıntı katmanı çıkarmak ve yapısal filtre ile yumuşatmak üzere ters çevirmişlerdir. Sonunda, kontrastı büyütmek ve fazla/az geliştirmeyi önlemek için bulanıklaştırma işleminden önce karanlık kanala uyarlanabilir bir geliştirme parametresi uyarlayarak başarılı bir çalışma ortaya koymuşlardır.

Düşük aydınlıklı görüntü iyileştirme için girdi görüntüler değişik uzaylara çevrilirler. Çevrilen uzayın önemli değişikliklere sebep olabilecek kanallarında işlemler yapılıp ardından tekran RGB kanalına çevrilerek iyileştirmeler yapılmaktadır.

Li ve ark. (2018), yaptıkları çalışmada girdiyi HSV uzayına çevirip V kanalındaki gürültüyü de düşünerek retineks ayrıştırmasıyla bu kanaldaki işlemlerini gerçekleştirmişlerdir. Ardından tekrar RGB uzayına geçirerek başarılı sonuç ortaya koymuşlardır.

Tanaka ve ark. (2019), yaptıkları çalışmada gradyanların koyu bölgelerde küçük olma eğilimlerinden ötürü girdiyi YCbCr uzayına çevirmişlerdir. Y(luminans) kanalında gradyanları geliştirerek başarılı sonuçlar göstermişlerdir.

Görüntüleri iyileştirmede görüntü işleme manuel olarak matematiksel işlemlerle ilerleme sağlarken, bu işlemleri otomatik şekilde yapan derin öğrenme ise görüntü işlemenin erişemediği özelliklere ulaşabilmektedir. Gün geçtikçe halka açık veri setlerinin internet ortamında yaygınlaşması, otomatik özellik çıkarımını gerçekleştiren derin öğrenme yöntemlerine olan ilgiyi artırmıştır. Mevcut düşük ışıkta görüntü geliştirme tekniklerinin çoğu, veriye dayalı tekniklerden ziyade model tabanlı tekniklerdir (Wang ve ark., 2020). Sadece son yıllarda, görüntü iyileştirme için makine öğrenimine dayanan yöntemler önemli sayılarda ortaya çıkmaya başlamıştır (Gómez ve ark., 2019). 2016'dan bu yana, görüntü iyileştirme için çeşitli derin öğrenme tabanlı yöntemler de ortaya çıkmıştır. Uçtan uca eğitim sayesinde, geleneksel düşük ışıkta görüntü işleme yöntemine göre iyi bir gelişme sağlanmıştır.

Tao ve ark. (2017), girdilerini bir koldan 3x3'lük filtreli evrişimden geçirmişlerdir. Aynı girdiyi bir de diğer koldan 1x1 çekirdek boyutlu evrişim mimarisinden geçirmişlerdir. Kullandıkları yöntemle başarılı bir düşük aydınlıklı görüntü iyileştirme yöntemi ortaya koymuşlardır.

Lore ve ark. (2017), yaptıkları çalışmalarında düşük ışıklı görüntülerde var olan gürültüler nedeniyle gürültü giderme üzerinde yoğunlaşmışlardır. Bu nedenle gürültü gideren bir derin kodlayıcı-kod çözücü ile yüksek aydınlıklı görüntü üretmişlerdir.

Ren ve ark. (2019), kodlayıcı-kod çözücü ve özyinelemeli yapay sinir ağının kuvvetlerini birleştiren bir çalışma tasarlamışlardır. Derin öğrenme mimarilerinin beraber kullanılmasının getirdiği güçlü başarıdan yararlanarak literatüre katkı sağlamışlardır.

Yang ve ark. (2020), özyinelemeli kodlayıcı-kod çözücülerden ürettikleri her bir çıktıyı iyileştirerek girdi görüntüler üretmişlerdir. Böylece şu ana kadar sunulan çalışmalardan çok farklı bir yöntem ortaya koymuşlardır.

Guo ve ark. (2020), en iyi eğriyi tahmin eden bir derin öğrenme mimarisi geliştirdiler. En iyi eğri tahminiyle düşük ışıklı görüntü iyileştirme çalışmalarına farklı bir bakış açısı sunmuşlardır.

Qu ve ark. (2020), GAN modelinin üretici kısmında kenar geliştirme, kodlayıcı ve dikkat içeren farklı bir GAN modeliyle başarılı bir çalışma sunmuşlardır. Farklı bir GAN modeliyle literatüre katkı sağlamışlardır.

Wang ve ark. (2020), ilk olarak kodlayıcı-kod çözücü derin öğrenme mimarisinden girdileri geçirmişlerdir. Ardından sıkma ve uyarma derin öğrenme mimarisinden geçiren bir yüksek aydınlıklı görüntü üretmişlerdir.

Lv ve ark. (2021), girdiyi sırasıyla dikkat mekanizması içeren U-Net, genişletilmiş evrişim, evrişim, U-Net mimarilerinden geçirmişlerdir. Ardından tekrar genişletilmiş evrişimden geçiren bir mimari tasarlamışlardır.

Jiang ve ark. (2021), dikkat mekanizmalı U-Neti GAN modelinin üretici kısmında barındıran ve aynı zamanda sınıflandırıcı kısmında da geleneksel ve lokal olarak 2 çeşit sınıflandırıcı ile düşük aydınlıklı görüntü geliştirmeye farklı bir bakış açısı sunmuşlardır.

Wei ve ark. (2022), girdiyi ilk öne HSV uzayına çevirmişlerdir. Ardından HSV uzayına çevrilmiş girdinin V kanalında kanal dikkat içeren bir U-Net mimarisiyle düşük aydınlıklı görüntü geliştirme çalışması sunmuşlardır.

Chen ve ark. (2022), yaptıkları çalışmada girdiyi ayrık dalgacık dönüşümünden geçirmişlerdir. Üç girdiyi genişletilmiş evrişim ve kanal mekanizmasından, bir girdiyi geleneksel uzamsal dikkatten geçirip bu çıktıları birleştirerek gelişmiş düşük aydınlıklı görüntü geliştirmişlerdir.

Wang ve ark. (2022), yaptıkları çalışmada basit olasılıklı dağılım yapmışlardır. Oluşturdukları farklı haritalar arasında şartlı öğrenme yapıp aynı girdiye farklı ağda uygulamış olduğu evrişim ve kalıntıların çıktılarını birleştirerek başarılı çalışma üretmişlerdir. Şartlı öğrenme için basit olasılık dağılım dönüşümü olan Normalleştirici Akış (Normalizing Flow) kullanarak Şartlı Kod-çözümleyici (Conditional Encoder) ile başarılı bir yöntem ortaya koymuşlardır.

Xu ve ark. (2022), çalışmalarında girdiyi yapısal ve doku haritalarına ayırmışlardır. Bu haritalardan elde ettikleri çıktıları evrişimlerle birleştirerek düşük aydınlıklı görüntü geliştirmeye farklı bir bakış açısı sunmuşlardır.

Kim ve ark. (2022), çalışmalarında girdiyi YCbCr uzayının Y(luminans) kanalında sırasıyla evrişim, kanal dikkat ve kalıntı bloklarından geçirmişlerdir. Bu bloklardan geçirilmiş çıktıyı ve Y(luminans) kanalından direk aldıkları çıktıyı birleştirdikten sonra Gauss filtresi ve ardından çekirdek yoğunluk tahmini olarak adlandırdıkları histogramdan geçirerek gelişmiş bir çalışma ortaya koymuşlardır.

Zhou ve ark. (2023), ilk olarak gürültüyü kaldırmışlardır. Ardından uyarlanabilir retineks ve etkili kanal dikkatle düşük aydınlıklı görüntü geliştirme çalışmalarına katkıda bulunmuşlardır.

Bu çalışma düşük aydınlıklı görüntülerin yüksek aydınlıklı görüntüye getirebilmek için derin öğrenme yöntemlerinden olan çeşitli dikkat mekanizmalarının kullanılması ve farklı dikkat mekanizmalarının da düşük aydınlıklı görüntüler üzerindeki etkilerinin değerlendirilmesi olarak özetlenebilir.

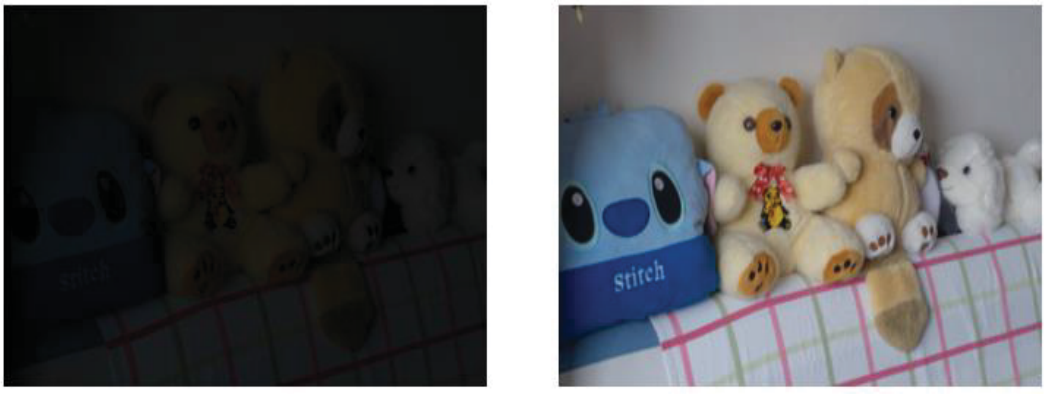
3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Veri kümesi

Düşük aydınlıklı görüntü iyileştirme çalışmalarına uzun yıllar çalışılmış olmasına rağmen epey bir zaman öncesine kadar YDA (Yüksek Dinamik Aralık) görüntülerinin veri seti kullanılmıştır. Fakat küçük ölçek ve kısıtlı sahnelerinden ötürü Wei ve ark. (2018) düşük aydınlıklı görüntü iyileştirme çalışmalarına özel LOL (Low Light Paired Dataset) (Wei ve ark., 2018) veri setini oluşturmuşlardır.

Düşük aydınlıklı iyileştirme için gerçek sahnelerden alınan LOL veri seti 500 adet az ve normal aydınlıklı görüntü çiftlerinden oluşmaktadır. 400x600 boyutunda olan 500 adet görüntü çiftleri 485 eğitim, 15 test için olacak şekilde ayrılmıştır. Veri setinde bulunan düşük ve normal aydınlıklı görüntü çiftlerine ait görüntüler Şekil 3.1.'de sunulmuştur.



Şekil 3. 1. Veri setinde yer alan örnek görüntüler (a)Düşük aydınlıklı (b)Normal aydınlıklı

Çoğu düşük ışıklı görüntü, poz süresi ve ISO değiştirilerek toplanırken, bazı kameraların konfigürasyonları sabittir. LOL veri seti oluşturulurken sentetik görüntüleri gerçek karanlık fotoğrafçılığın özelliklerine uydurmak için düşük ışıklı görüntülerin aydınlatma dağılımı analiz edilmektedir (Wei ve ark., 2018). MEF (Ma

ve ark., 2015), NPE (Pizer ve ark., 2018), LIME (Guo ve ark., 2016), DICM (Lee ve ark., 2013) ve Fusion (Dabov ve ark., 2006) veri kümelerinin görüntüleri YCbCr kanalına dönüştürülüp ve Y kanalının histogramı hesaplanılmıştır. Ayrıca RAISE (Dang ve ark., 2015)'ten 1000 ham görüntü toplanıp normal ışıklı görüntüler olarak alınmıştır ve Y kanalının histogramı hesaplanmıştır. Ham görüntüler, dönüştürülen sonuçlardan daha fazla bilgi içermektedir. Ham görüntüler üzerinde çalışırken, piksel değerleri oluşturmak için kullanılan tüm hesaplamalar, temel üzerinde tek bir adımda gerçekleştirilmiştir. RAISE (Dang ve ark., 2015)'deki 1000 ham görüntü düşük ışıklı görüntüler sentezlemek için kullanılmıştır. Adobe Lightroom tarafından sağlanan arayüz kullanılmaktadır ve düşük ışıklı görüntülerin Y kanalının histogramını sonuca uydurmak için farklı tür parametre sayıları denenmektedir. Sentetik görüntülerin aydınlatma dağılımı, düşük ışıklı görüntülerinkiyle eşleştirilmektedir. Sonunda bu ham görüntüler 400×600 olarak yeniden boyutlandırılarak veri kümesi elde edilmektedir.

3.2. Yöntem

3.2.1. Evrişimli sinir ağları

Girdi verisi olarak görüntü kullanan evrişimli sinir ağı, girdinin özelliklerini(features) çıkararak görüntüleri ayırt edebilme yeteneğiyle sınıflandırma gerçekleştiren bir derin öğrenme algoritmasını temsil eder. CNN filtre öğrenme yeteneği sayesinde başka sınıflandırma algoritmalarına nispeten ön işleme gereksinimi azalmaktadır. CNN mimarisi, Evrişim Katmanı (Convolutional Layer), Havuzlama Katmanı (Pooling Layer), Normalizasyon Katmanı, Düzleştirme Katmanı (Flattening Layer), Tam Bağlantılı Katman (Fully Connected Layer), Bırakma Katmanı (Dropout Layer) ve aktivasyon fonksiyonlarının uygulandığı katmanlardan oluşur.

Giriş görüntüsünde özellikleri ayıklayan Evrişim Katmanı, görüntü üzerinde işlem yapan ilk katmandır. İçlerinde belirli değerler barındıran pikseller matrisi denilebilen görüntüler evrişim katmanından geçirilirler. Bu katmanda görüntü matrisleri üzerinde, görüntü matrislerinin boyutundan daha küçük olan filtre matrisleri gezdirilerek görüntlerin belirli özelliklerini içeren çıktılar elde edilir. Görüntü üzerinde gezdirilen filtre, görüntüdeki kenarları tespit eden bir filtre olabilir veya başka özellikleri çıkaran filtreler de olabilir.

Evrişim katmanında matris formatına dönüştürülen görüntüler üzerinde filtreler sırayla kaydırma (stride) işlemi ile belli bir oranla kaydırılır. Giriş görüntüsündeki değerler ile üst üste oturtulduğunda karşılık gelen filtredeki değerler çarpılarak toplanır ve merkez konumdaki piksel değeri hesaplanır. Filtre tüm görüntü üzerinde kaydırma işlemi ile gezdirilerek bu işlem tamamlanır. Bu işlem sonucunda görüntünün önemli noktalarının ortaya çıkarıldığı yeni bir görüntü oluşur.

Evrişim işleminden sonra giriş boyutu azaldığından bunun önüne geçmek için giriş matrisine ekstra pikseller eklenerek padding(dolgulama) yapılır. Giriş matrisi nxn, filtre matrisi fxf şeklinde düşünülürse padding işlemiyle giriş matrisinin boyutunun aynı kalabilmesi için (n+2p-f+1)x(n+2p-f+1) formülü kullanılır. Bu formülde "p" giriş matrisine eklenecek olan piksel boyutu yani padding değeridir ve bu da p=(f-1)/2 şeklinde hesaplanılır.

Evrişim katmanından sonra sınıflandırmada parametre sayısının azaltılması için havuzlama katmanı kullanılır. Havuzlama katmanında boyut her ne kadar azaltılsa da önemli bilgiler korunur. Ayırt edici özellikler ön plana çıkarılarak bir sonraki katmana iletilir. Maksimum ve ortalama havuzlama en çok kullanılan havuzlama türlerindendir. Maksimum havuzlama işleminde filtre, kapsadığı alandaki en büyük sayıyı, ortalama havuzlama işleminde ise kapsanan alandaki sayıların ortalamasını alır.

Mimarinin son katmanında bütün düğüm ve nöronların bir sonraki katmanlara bir yapay sinir ağıyla bağlanılan Tam Bağlantı Katmanı(Fully Connected Layer) gerçekleştirilir. Evrişimli Katman ile Havuzlama Katmanları'ından geçen matris halindeki veriler düz bir vektör haline getirilen bu işleme düzleştirme(flattening) denir.

Düzleştirme(flattening) işleminin ardından her giriş tüm nöronlara bağlanarak tam bağlantılı katman gerçekleştrilir. Nöronlarda önceki katmanlardan gelen özellikler tutulur ve veriler ağırlıklandırılarak birleştirilir ve bir kayıp fonksiyonu sayesinde nöronlara eğitim boyunca verilecek en uygun ağırlık bulunur. Son olarak olasılıksal sınıflandırma yapılır.

Yapay sinir ağlarında modeller başka veri setlerinde aynı başarıyı gösterip genelleştirme yapamazlar başka bir deyişle ezberlemeye(overfitting) engel olmak için ağın bazı düğümleri pasif hale getirilerek bırakma(dropout) işlemi yapılır.

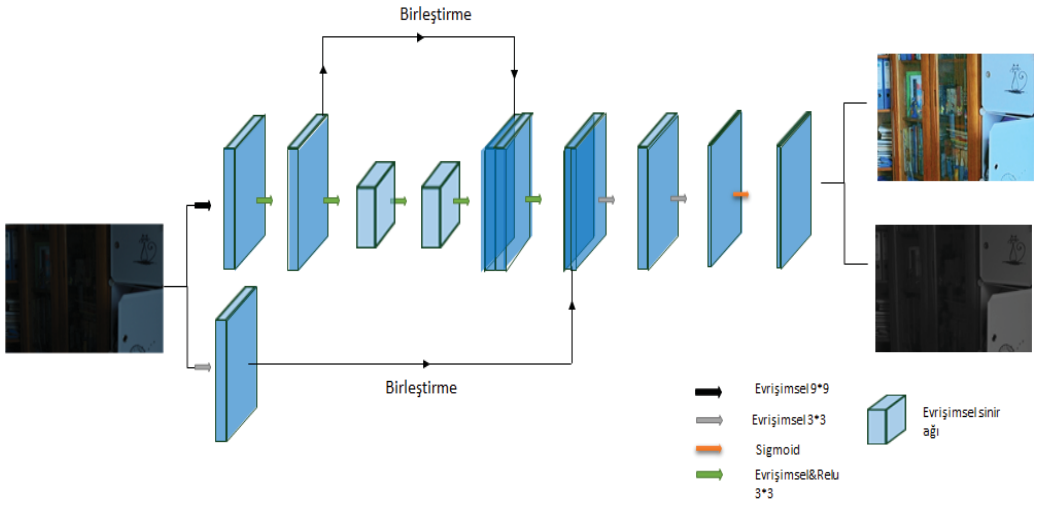
3.2.2. SSIENet

Bu çalışmada, düşük aydınlıklı görüntü iyileştirme algoritması olan Zhang ve arkadaşlarının (Zhang ve ark., 2020) SSIENet algoritması iskelet olarak kullanılmıştır. SSIENet düşük aydınlıklı girdi görüntüyü Retineks teorisiyle (Bölüm 1.3.'de açıklanmıştır) çoğaltarak girdi görüntüden daha fazla özellik elde etmeyi amaçlamıştır. SSIENet kendine özgü katman sayısından oluşan evrişimsel sinir ağlarıyla düşük aydınlıklı görüntü iyileştirme sağlamıştır. İlk olarak düşük aydınlıklı girdi görüntüsünü alıp ardından model uygulanmıştır. Sigmoid katmanında retineks uygulanarak yansıma ve aydınlatma bileşenlerine ayrıştırılmıştır. Ancak sadece retineks uygulanarak elde edilen bileşenlerin kötü konumlanmış bir sorun olması nedeniyle Bayes formülüne göre problem ifade edilmiştir. Yansıma ve aydınlatma bileşenlerinin önceki olasılıkları eklenmiştir. Aydınlatma ve yansıma kaybının yanı sıra yeniden yapılandırma kaybı da hesaplanılmıştır. Yansıtma kaybına bakılacak olursa SSIENet'in yansıma kaybında var olanlardan farklı olarak yeni bir mesafe ölçüm yöntemi kullanılmıştır. Bu yöntem ile işlenen bilgi yeterli bilgiye sahip, orijinal görüntü bilgilerine uygun olmanın yanı sıra histogram eşitleme ile girdi büyük ölçüde iyileştirilmiştir. Yansıma kaybı için maksimum kanal üzerinde işlemlerin yapılması tercih edilmiştir. Maksimum entropiye dayalı Retineks modeliyle elde edilen yansıma çıktısı test için kullanılmıştır. SSIENet'in mimari yapısı Şekil 3.2'de gösterilmiştir.

3.2.3. Dikkat mekanizmaları

Dikkat mekanizması, girdi verilenin önemli kısımlarına yoğunlaşırken, önemsiz kısımlarını göz ardı eden bir derin öğrenme yöntemidir. Dikkat mekanizması ilk olarak doğal dil işlemede (NLP) encoder-decoder tabanlı makine çevirme sistemine entegre şekilde bir gelişme olarak ortaya atıldı. Ardından bu mekanizma ve çeşitleri bilgisayarlı görü de olmak üzere birçok alanda kullanılmaya başlandı.

Bahdanau ve arkadaşları 2014 (Bahdanau ve ark., 2014) yılında ilk dikkat mekanizmalarını önermeden önce makine çevirilerinde encoder-decoder RNN ve LSTM'leri kullanılmaktaydı. Ecoder LSTM'de giriş cümlesi işlenir ve son gizli durumu bir bağlam vektörüne kodlanır. Kodlayıcının gizli durumları göz ardı edilerek son gizli durum ilk durummuş gibi varsayılarak işleme alınır. Decoder LSTM'de bir cümle içindeki kelimeleri ard arda üretir. Kodlayıcıda giriş cümlesi okunur ve anlamlandırılmaya çalışılır, kod çözücüde bağlam vektörü, giriş cümlesini sadece görerek çevirir. Ancak bu durumda encoder daha uzun cümleleri kötü anlamlandırırsa kötü sonuç ortaya çıkar. Cümleyi çevirirken bazı girdi kelimelere diğerlerine göre daha fazla önem vermenin bir yolu bulunmamaktadır.



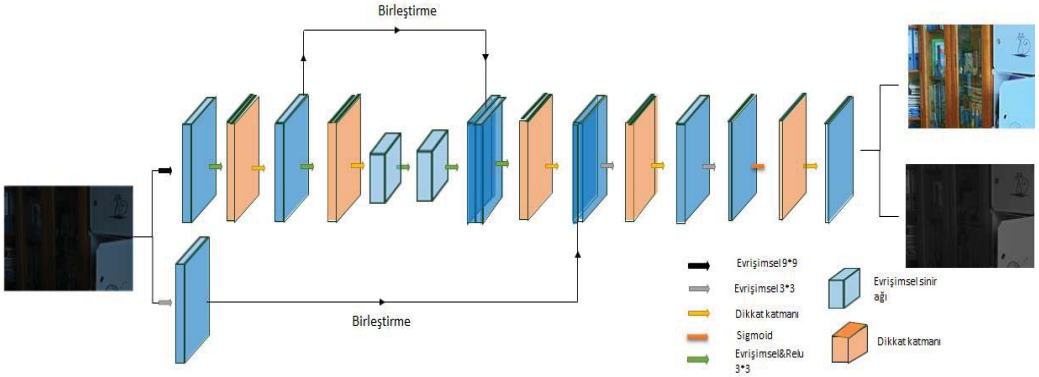
Şekil 3. 2. Baz alınan SSIENet iskelet yapı (Zhang ve ark., 2020)

Bahdanau ve arkadaşları (Bahdanau ve ark., 2014), yalnızca tüm girdi sözcüklerinin bağlam vektöründe dikkate alınabileceğini değil, aynı zamanda her birine göreli önem verilmesi gerektiğini öne süren bir fikir ortaya attılar. Bu nedenle, dikkat mekanizmaları bir cümle oluşturduğunda, en uygun bilginin mevcut olduğu kodlayıcı gizli durumlarında bir dizi konum arayarak dikkati sağlar.

Dikkat mekanizmaları başlangıçta cümle içerisindeki her kelimeyi vektöre dönüştürüp ardından bu kelimelerden hangisinin önemli ya da hangisinin önemsiz olduğuna karar vermek için doğrusal kombinasyon ile seçilir. Olasılığı yüksek olanı önemli diye belirleyerek seçim işlemini gerçekleştirir. Dikkat mekanizmasının

metindeki bu ilerleyişi görüntüde kelime yerine baskın piksellerin aktarılması, baskın olmayanların göz ardı edilmesi şeklinde ilerler.

SSIENet kontrast geliştirme çalışmasından yola çıkarak ve dikkat mekanizmalarının bilgisayarlı görüdeki başarısı göz önüne alınarak SSIENet'e dikkat mekanizması ekleyerek farklı dikkat mekanizmalarının düşük aydınlıklı görüntüler üzerinde nasıl etkileneceğini inceledik. Önerdiğimiz yöntemi sıklıkla kullanılan dikkat mekanizmalarıyla etkisini ölçtük. Oluşturmuş olduğumuz mimari yapısında kullandığımız dikkat mekanizmalarını farklı katmanların farklı yerlerine ekleyerek denedik. Mimarinin farklı katmanlarına eklediğimiz dikkat mekanizmalarının bazı sayısal sonuçları Çizelge 3.1.'de verilmiştir. En iyi sonucu aldığımız katmanların bulunduğu mimari yapımız Şekil 3.3'te gösterilmiştir.



Şekil 3. 3. SSIENet (Zhang ve ark., 2020) mimarisinden uyarlanmış önerilen mimari

Çizelge 3. 1. Farklı katmanlara eklenen dikkat mekanizmalarının PSNR sonuçları

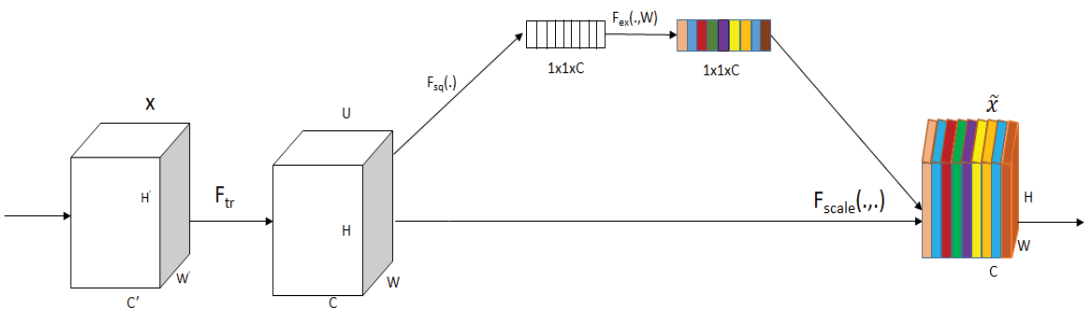
Koordinat Dikkat mekanizması	**PSNR**
Conv1,conv2,conv3,conv5,conv6,conv8	19.064
Conv1,conv2,conv3,conv5,conv6,conv7	18.553
Darboğaz Dikkat mekanizması	**PSNR**
Conv1,conv2,conv3,conv5,conv6,conv8	18.839
Conv1,conv2,conv3,conv5,conv6,conv7	18.955
Kanal Dikkat mekanizması	**PSNR**
Conv1,conv2,conv3,conv5,conv6,conv8	18.909
Conv1,conv2,conv3,conv5,conv6,conv7	18.032
Sıkma ve uyarma Dikkat mekanizması	**PSNR**
Conv1,conv2,conv3,conv5,conv6,conv8	20.024
Conv1,conv2,conv3,conv5,conv6,conv7	19.922
Etkili kanal Dikkat mekanizması	**PSNR**
Conv1,conv2,conv3,conv5,conv6,conv8	19.174
Conv1,conv2,conv3,conv5,conv6,conv7	19.751
Uzamsal ve kanal sıkma ve uyarma Dikkat mekanizması	**PSNR**
Conv1,conv2,conv3,conv5,conv6,conv8	18.839
Conv1,conv2,conv3,conv5,conv6,conv7	18.950

3.2.3.1. Sıkma ve uyarma dikkat ağı

Hu ve ark. (2018) tarafından geliştirilen Sıkma ve uyarma dikkat mimarisi bu çalışmada kullanılmıştır. Sıkma ve uyarma dikkat mekanizması geleneksel bilgide modele destek olur. Son sınıflandırma kararına katkı sağlar ve bilgilendirici kanallarla modeli güçlendirir. $F_{tr} : X \rightarrow U$, $X \in R^{H' \times W' \times C'}$, $U \in R^{H \times W \times C}$ şeklinde bir dönüşümle oluşturulabilen hesaplama birimidir. Takip eden işlemde F_{tr} evrişim işlemine koyulur. V= [v1,v2,…vc] vc'nin c. filtresinin parametrelerini ifade eden filtre çekirdeği setidir. F_{tr} U=[u1,u2,…uc] şeklinde yazılabilir,

$$u_c = v_c * X = \sum_{s=1}^{C'} v_c^s * X^s \tag{3.2}$$

Burada * evrişimdir. $V_c=[v_c^1,v_c^2,\ldots v_c^{c1}]$ ve $X=[x^1,x^2,\ldots,x^{c1}]$, v_c^s iki boyutlu çekirdekken ve bu yüzden x'in karşılık gelen kanalı üzerinde hareket eden v_c'nin tek kanalını gösterir. Çıktı tüm kanallar üzerinden toplama ile üretildiğinden, kanal bağımlılıkları örtülü olarak v_c'ye gömülür, fakat bu bağımlılıklar filtreler tarafından yakalanan uzaysal ilişkiyle karıştırılır. Onlar alt dönüşümlerle faydalanabilsin ve daha az kullanışlı olanları bastırabilmesi amacıyla bilgilendirici özellikler için ağın duyarlılığını geliştirebilmektir. Sıkma ve Uyarma bloğu Şekil 3.4'de gösterilmiştir.



Şekil 3. 4. Sıkma ve uyarma ağı (Hu ve ark., 2018)

3.2.3.2. Kanal dikkat ağı

Bastidas ve ark. (2019) tarafından geliştirilen Kanal dikkat mekanizması tek kanallar üzerinde yumuşak dikkat kullanan bir derin öğrenme ağıdır. Her bir kanal için

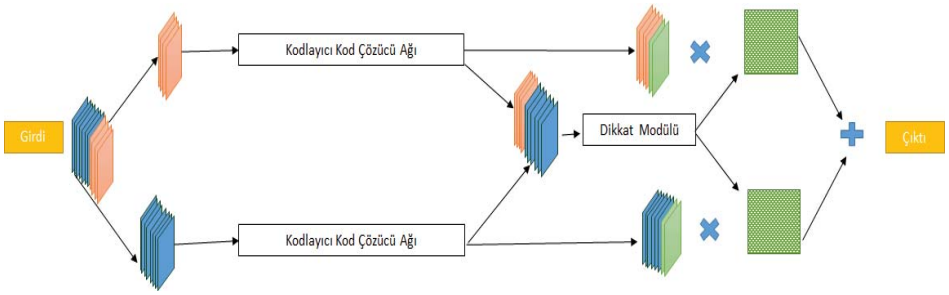
s∈{1,…,S} verilen özellik haritaları X_s, üretilen final tahmin :

$$Y=\sum_{s=1}^{S} \boldsymbol{W_S}.\text{Softmax}(X_s) \tag{3.3}$$

W_s ağırlıklar kanallardan birleştirilen özellik haritalarını giriş olarak alan Φ dikkat ağı tarafından hesaplanılır. İlk 5x5 çekirdek ile piksel bazlı softmax ve S filtrelerle 1x1 evrişim tarafından izlenen K filtrelerle 2 evrişim katmanı kullanılır.

$$W=\text{Softmax}(\Phi\ (X_1 \oplus X_2 \oplus \ldots X_S)) \tag{3.4}$$

Tüm ağın ortak eğitimi boyunca, kanal dikkat ağı Şekil 3.5'de görüldüğü üzere görüntü bağımlı şekilde her bir kanalın ağırlık değerlerini öğrenir. Hem dikkat hem birleştirme yaklaşık olarak toplam aynı parametre sayısına sahiptirler, çünkü ikisi de paylaşılmayan parametrelerle çoklu kanala sahiptirler.



Şekil 3. 5. Kanal dikkat ağı (Bastidas ve ark., 2019)

3.2.3.3. Etkili kanal dikkat ağı

Etkili kanal dikkat ağı, sıkma ve uyarma ağının içinde kanal dikkat modülünü detaylandırarak kanallar arası etkileşim ve boyutsal küçültmenin etkilerini de göz önüne alıp etkili bir kanal dikkat mekanizması üretmiştir. Başlangıçta sıkma ve uyarma ağının içinde kanal dikkati incelediğimizde $X \in R^{WXHXC}$ bir evrişim bloğunun çıktısıdır, burada W genişlik, H yükseklik ve C kanal boyutudur. Sıkma ve uyarma bloğundaki kanalların ağırlıkları şöyle hesaplanılır (Wang ve ark., 2020):

$$\omega = \sigma(f_{\{w1\,,\,w2\}}(g(X))) \tag{3.5}$$

Burada $g(x)=\frac{1}{WH}\sum_{i=1,j=1}^{W,H} \boldsymbol{X_{ij}}$ kanal bazlı Küresel Ortalama Havuzlama(GAP) ve σ sigmoid fonksiyonudur. y=g(x), $f_{\{w1\,,\,w2\}}$ formu;

$$f_{\{W1,W2\}}(y) = W_2 ReLU(W_1 y) \quad (3.6)$$

Burada RELU (Rectified Linear Unit) aktivasyon fonksiyonunu temsil etmektedir. Yüksek model karmaşıklığından kaçınmak için W_1 ve W_2'nin boyutları C x $(\frac{C}{r})$ ve $(\frac{C}{r})$ x C şeklinde ayarlanır. $f_{\{W1\ ,\ W2\ \}}$ 'in kanal dikkat bloğunun tüm parametrelerini içermektedir (Wang ve ark., 2020). Yukarıdaki eşitlikte boyut azaltma model karmaşıklığını azaltabilirken, kanal ve kanalın ağırlığı arasındaki doğrudan karşılığını tahrip eder. Bu nedenle kanal boyut azaltma olmaksızın Etkili Kanal Dikkat modülü geliştirilmiştir.

Boyut azaltma olmaksızın $y \in R^C$ toplu özellik göz önüne alındığında kanal dikkat öğrenme (Wang ve ark., 2020);

$$\omega = \sigma(Wy) \quad (3.7)$$

Burada W CxC parametre matrisidir.

$$W = \begin{cases} \text{Wvar2} = \begin{bmatrix} W^{1,1} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & W^{C,C} \end{bmatrix}, \\ W_{var3} = \begin{bmatrix} W^{1,1} & \cdots & W^{1,C} \\ \vdots & \ddots & \vdots \\ W^{1,C} & \cdots & W^{C,C} \end{bmatrix} \end{cases} \quad (3.8)$$

Burada W_{var2} köşegen matristir, C parametrelerini içerir; W_{var3} CxC parametrelerini içeren tam matristir.

$$W_G = \begin{bmatrix} W_G^1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & W_G^G \end{bmatrix} \quad (3.9)$$

Burada G grupların her biri C/G kanallar içeren kanala ayrılıyor ve yerelde çapraz kanal etkileşimini ele geçiren bağımsız bir şekilde her bir gruptaki kanal dikkati öğreniyor. Buna göre, C^2/G parametreler içeriyor. Evrişim açısından ve yukarıdaki eşitlik sırasıyla Tam Bağlantı(FC) katmanı ve grup evrişimler derinlik bazlı ayrılabilir evrişim olarak kabul edilebilir. Burada grup evrişimlerle SE blok(SE-GC) $\sigma(GC_G(y)) = \sigma(W_G y)$ olarak gösterilmektedir. Özellikle kanal dikkati öğrenmek için W_k matrisi bandına çalışılmaktadır ve W_k (Wang ve ark., 2020);

$$\begin{bmatrix} w^{1,1} & \cdots & & w^{1,k} & 0 & 0 & \ldots & \cdots & 0 \\ 0 & w^{2,2} & \cdots & w^{2,k+1} & 0 & \cdots & \cdots & 0 & \\ \vdots & \vdots & & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & \ldots & 0 & 0 & \ldots & w^{c,c-k+1} & \ldots & w^{c,c} & \end{bmatrix} \quad (3.10)$$

Eşitlik(3.10)'daki W_K eşitlik(3.9)'dakinden genellikle daha az olan kxC parametre içerir. Ek olarak eşitlik(3.10), eşitlik(3.9)'daki farklı gruplar arasındaki tam bağımsızlıktan kaçınır. Eşitlik(3.9)'daki metod eşitlik(3.10)'daki SE-GC'den yüksek performans gösterir. Eşitlik(3.10)'a gelince y_i'nin ağırlığı y_i ve k komşuluğu ile arasındaki sadece etkileşim düşünülerek hesaplanılır, örneğin,

$$W_i = \sigma\left(\sum_{j=1}^{k} \omega_i^j y_i^j\right), y_i^j \in \Omega_i^k \quad (3.11)$$

Ω_i^k burada y_i'nin k bitişik kanallarının ayarıdır.

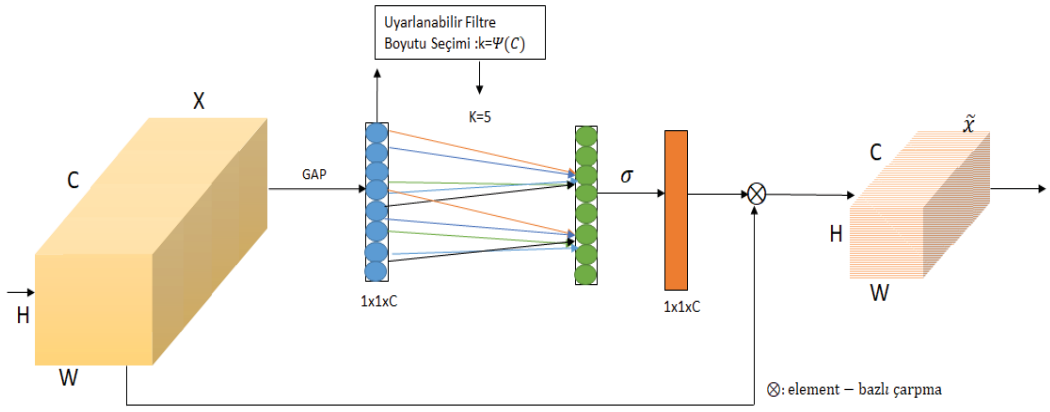
Daha etkili bir yol aynı öğrenilen parametreleri tüm kanallara paylaştırmaktır, örneğin ,

$$W_i = \sigma\left(\sum_{j=1}^{k} w^j y_i^j\right), y_i^j \in \Omega_i^k \quad (3.12)$$

Böyle strateji filtre boyutu k ile hızlı bir 1D evrişim tarafından kolayca uygulanabilir, örneğin,

$$W = \sigma(C1D_k(y)) \quad (3.13)$$

Burada C1D 1D evrişimi göstermektedir. Burada eşitlik(3.11)'deki metod sadece k parametrelerini içeren Şekil 3.6'da mimari yapısı verilen Etkili Kanal Dikkat modül olarak adlandırılır.



Şekil 3. 6. Etkili kanal dikkat ağı(Wang ve ark., 2020)

3.2.3.4. Darboğaz dikkat ağı

Park ve ark. (2018) tarafından geliştirilen darboğaz dikkat mekanizması verilen giriş özellik haritası $F \in R^{CXHXW}$ için, $M(F) \in R^{CXHXW}$ 3D dikkat haritası çıkarmaktadır. Onarılmış özellik haritası F' şöyle hesaplanılır:

$$F' = F + F \otimes M(F) \tag{3.14}$$

Burada $\otimes$ element bazlı çarpmayı göstermektedir. Gradyan akış olanağı için dikkat mekanizmasıyla birlikte artık öğrenme şeması benimsenmektedir. Etkili güçlü modül tasarımı için, $M_c(F) \in R^C$ ilk kanal dikkat ve $M_s(F) \in R^{HXW}$ uzamsal dikkat diye iki branşa ayrıldıktan sonra dikkat haritası M(F) şöyle hasaplanmaktadır:

$$M(F) = \sigma\,(M_c(F) + M_s(F)) \tag{3.15}$$

Burada σ sigmoid fonksiyonunu temsil etmektedir. Eklemeden önce iki branş çıktıları R^{CXHXW} için yeniden boyutlandırılmaktadır.

Kanal dikkat branşı: Her bir kanal özel özellik yanıtı içerdiğinden, kanal branşında kanallar arası ilişki kullanılmaktadır. Her bir kanaldaki özellik haritasını toplamak için, özellik haritası F üzerinde geleneksel ortalama havuzlama alınır ve $F_C \in R^{CX1X1}$ kanal vektörü üretilir. Bu vektör her bir kanalda evrensel bilgi kodlar. F_c kanal vektörden dikkat çapraz kanalları tahmin etmek için, gizli katmanla birlikte çok katmanlı algılayıcı(multi-layer perceptron) kullanılmaktadır. Parametre kaydetmek için gizli aktivasyon boyutu $R^{C/Rx1x1}$ ayarlanır, burada r azaltma oranıdır. Çok katmanlı algılayıcıdan sonra uzamsal branş çıktısı ile ölçeği ayarlamak için yığın

normalizasyon(batch normalization) eklenir. Kısacası, kanal dikkat şöyle hesaplanımaktadır (Park ve ark., 2018):

$$M_c(F) = BN(MLP(AvgPool(F))) \\ = BN(W_1(W_0 AvgPool(F) + b_0) + b_1) \quad (3.16)$$

Burada $W_0 \in R^{C/r \times C}$, $b_0 \in R^{C/r}$, $W_1 \in R^{C \times C/r}$, $b_1 \in R^{C}$.

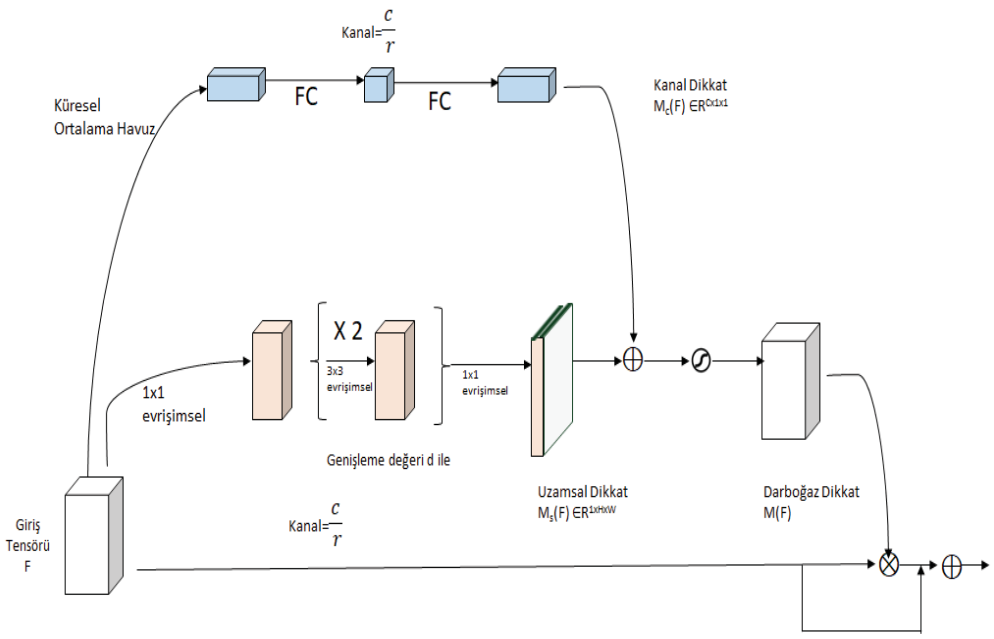
Uzamsal dikkat branşı: Uzamsal branş farklı uzamsal lokasyonlarda özellikleri bastırmak ya da vurgulamak için $M_s(F)$ uzamsal dikkat haritası üretir. Bağlamsal bilgi uzamsal lokasyon üzerinde odaklanılması gereken önemli bilgidir. Etkili bir şekilde bağlamsal bilgiyi yükseltmek için geniş alıcı alana sahip olmak önemlidir. Yüksek verimlilikle alıcı alanları genişletmek için genişletilmiş evrişim uygulanmaktadır. $F \in R^{CXHXW}$ özellik entegre için 1X1 evrişim kullanarak $R^{C/RxhxW}$ azaltılmış boyutta tasarlanılır ve kanal boyutu özellik harita çaprazı sıkıştırılır. Basitlik için azaltma oranı kanal branşıyla aynı kullanılır. Azaltmadan sonra, etkili bağlamsal bilgi kullanmak için 2 tane 3X3'lük genişletilmiş evrişim uygulanır. Son olarak, 1X1 evrişim kullanarak R^{1XHXW} uzamsal dikkat haritası için özellikler tekrar azaltılır. Ölçeği ayarlamak için, uzamsal branşın sonunda yığın normalizasyon(batch normalization) katmanı uygulanır. Kısacası, uzamsal dikkat şöyle hesaplanılmaktadır (Park ve ark., 2018):

$$M_S(F)=BN(f_3^{1X1}(f_2^{3X3}(f_1^{3X3}(f_0^{1X1})))) \quad (3.17)$$

Burada f evrişim işlemini göstermektedir, BN yığın normalizasyonu göstermektedir ve üst simgeler evrişim filtre boyutlarını göstermektedir. Kanal azaltmak için 2 tane 1X1 evrişim kullanılmaktadır. Orta düzeydeki 3X3 genişletilmiş evrişimler geniş alıcı alanlarla bağlamsal bilgi toplamada uygulanılır.

İki dikkat branşın kombinasyonu: İki dikkat branşından $M_c(F)$ kanal dikkat ve $M_s(F)$ uzamsal dikkat elde edildikten sonra final 3D dikkat haritası M(F) üretmek için birleştirilir. Dikkat haritası farklı boyutlara sahip olduğundan, birleştirmeden önce R^{CXHXW} dikkat haritaları genişletilir. Bu kombinasyon element bazlı toplamayla yapılır. Sonra 0-1 aralığında final 3D dikkat haritası M(F) elde etmek için sigmoid fonksiyonundan geçirilir. Bu 3D dikkat haritası giriş özellik haritasıyla element bazlı çarpılır sonra onarılmış özellik haritasını F' elde etmek için onarılmış özellik haritası

orijinal giriş özelliğine eklenir (Park ve ark., 2018). Darboğaz Dikkat Mekanizmasının yapısı Şekil 3.7'de verilmiştir.



Şekil 3. 7. Darboğaz dikkat ağı(Park ve ark., 2018)

3.2.3.5. Koordinat dikkat ağı

Hou ve ark. (2021) tarafından geliştirilen Şekil 3.8'de mimari yapısı verilen Koordinat dikkat ağı koordinat bilgi yerleştirme ve koordinat dikkat üretme olarak 2 adımdan oluşur. Kesin konum bilgileriyle uzun mesafe etkileşimleri uzamsal olarak yakalamak adına geleneksel havuzlamayı eşitlik(3.18)'deki gibi formülize edilmektedir. X girişi göz önüne alındığında, (H, 1) veya (1, W) her kanalı sırasıyla yatay koordinat ve dikey koordinat boyunca kodlamak için iki uzamsal havuz çekirdeği kapsamı kullanılır. Böylece, c. kanalın h yüksekliğindeki çıkışı şu şekilde formüle edilebilir (Hou ve ark., 2018):

$$Z_c^h(h)=\frac{1}{W}\sum_{0\le i<W} x_c(h,i) \tag{3.18}$$

w genişliğindeki c. kanalın çıktısı şöyle yazılır,

$$Z_c^w(w)=\frac{1}{H}\sum_{0\le j<H} x_c(j,w) \tag{3.19}$$

(3.18) ve (3.19) eşitliklerle kesin konumsal bilgiyi kodlama ve geleneksel alıcı alana olanak verilir. Basit ve ucuz, etkileşim bölgelerini etkin şekilde vurgulayabilen, mevcut koşullarda gerekli olduğu gösterilen kanallar arası ilişkileri etkin bir şekilde yakalayabilen bir başka dönüşüm uygulanmaktadır. Eşitlik(3.18) ve eşitlik(3.19) önce birleştirilir ve sonra paylaşılan 1x1 evrişim dönüşüm fonksiyonu F1 onlara gönderilir,

$$F=\delta(F_1([z^h,z^w])) \tag{3.20}$$

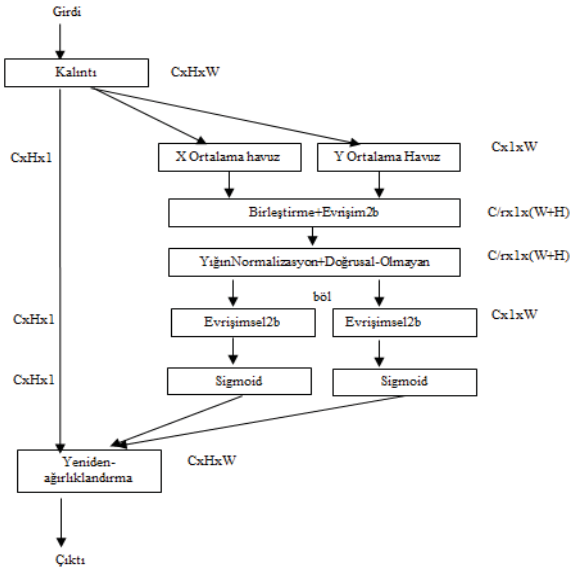
Burada [.,.] uzamsal boyutla beraber birleştirme işlemidir, δ doğrusal olmayan aktivasyon fonksiyonu, ve $f\in R^{C/rX(H+W)}$ hem dikey hem yatay yönde uzamsal bilgiyi kodlayan orta seviye özellik haritasıdır. Burada r azaltma oranıdır, $f^h\in R^{C/Rxh}$ ve $f^w\in R^{C/rXW}$ iki tensöre ayrılır. Diğer iki 1x1 evrişim dönüşümleri F_h ve F_w X girişi için aynı kanal sayısıyla f^h ve f^w ayırmada kullanılır,

$$g^h=\sigma(F_h(f^h)) \tag{3.21}$$

$$g^w\sigma(F_w(f^w)) \tag{3.22}$$

burada σ sigmoid fonksiyonudur. Sonunda koordinat dikkat fonksiyonu Y şöyle yazılır:

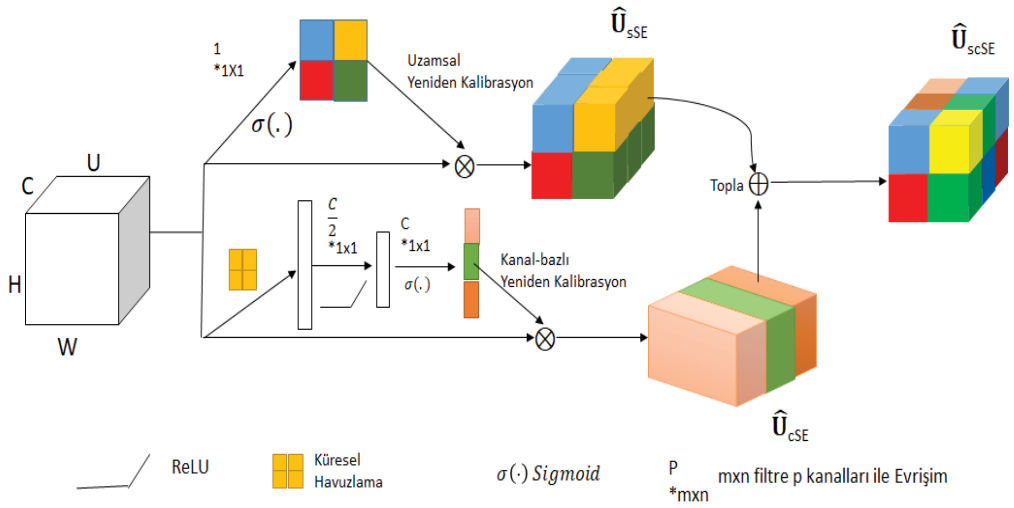
$$y_c(i,j)= x_c(i,j)\ X\ g_c^h(i)\ X\ g_c^w(j) \tag{3.23}$$



Şekil 3. 8. Koordinat dikkat ağı (Hou ve ark., 2021)

3.2.3.6. Uzamsal ve kanal sıkma ve uyarma dikkat ağı

Roy ve ark. (2018) tarafından geliştirilen Şekil 3.9'da mimari yapısı verilen uzamsal ve kanal sıkma ve uyarma dikkat ağı, eş zamanlı olarak kanal bazlı ve uzamsal U girişini yeniden kalibre eder. Kanal ve uzamsal uyarmanın eleman bazlı eklemesiyle $\hat{\boldsymbol{U}}_{scSE}=\hat{\boldsymbol{U}}_{cSE}+\hat{\boldsymbol{U}}_{Sse}$, eş zamanlı uzamsal ve kanal sıkma ve uyarma ağı elde edilir. Hem uzamsal hem kanal yeniden ölçeklendirildiğinde daha yüksek önem elde edildiğinden, giriş özellik haritası U'nun (i,j,c) konumuna daha yüksek aktivasyon verilir. Böylece ağ çok daha anlamlı özellik haritaları öğrenir.



Şekil 3. 9. Uzamsal ve kanal sıkma ve uyarma (Roy ve ark., 2018)

3.2.4. Değerlendirme ölçütleri

Bu bölümde düşük aydınlıklı görüntü iyileştirme yöntemlerinin başarımlarını sayısal olarak değerlendirmek için geliştirilmiş ve literatürde sıkça kullanılan görüntü kalite metriklerinden PSNR(Peak Signal-to-Noise Ratio), SSIM(Structural Similarity Index Measure), LRI(Local Radius Index) ve NSER(Non-Shift Edge Based Ratio) metrikleri tanıtılmaktadır. Tanıtılan PSNR, SSIM, LRI ve NSER metrikleri bu tez çalışmasında düşük aydınlıklı görüntü iyileştirme metriklerinin objektif olarak karşılaştırılması maksadıyla kullanılmıştır.

PSNR, MSE (Mean Squared Error) olan ortalama kare hatasından üretilen objektif bir metriktir. Bu metrik maksimum piksel yoğunluğunun bozulmanın oranını vermektedir. Bu oran genellikle orijinal ve iyileştirilmiş görüntü arasında bir kalite ölçüsü olarak kullanılmaktadır. Her piksel, bir resim iyileştirildiğinde ve daha sonra iyileşmişken değişebilen bir renk değerine sahiptir. Sinyaller daha geniş bir renk aralığına sahip olabildiğinden, PSNR(3.24) genellikle logaritmik bir ölçek olan desibel cinsinden ifade edilir. PSNR değeri ne kadar yüksek olursa iyileştirilmiş görüntünün kalitesi de doğru orantılı olarak o kadar iyi olur.

$$\text{PSNR(x,y)} = \frac{10\log_{10}[\max(\max(x),\max(y))]^2}{(x-y)^2} \tag{3.24}$$

SSIM, temel olarak görüntülerden seçilen parçaların birbiri ile tutarlılığını ölçerek yapısal benzerliği baz alan bir görüntü kalite değerlendirme metriğidir. Kaynak görüntülerden seçilen her bir parça parlaklık, kontrast ve yapı olmak üzere üç bileşene ayrılarak değerlendirilir. Görünürlük ve kontrast doğru orantılı olduğu için bütün parçalardan en büyük kontrasta sahip parça ideal parça olarak nitelendirilir. Ardından girdi görüntülerden alınan her bir parçanın çıktı görüntüye ne kadar etki ettiğine dair bir ağırlık belirlenir. En yüksek kontrast değere sahip ideal parça ve girdi görüntüden elde edilen her bir parçanın çıktı görüntüye etki ettiği ağırlık değerleri vektörel olarak çarpılır. Elde edilen değer ($\hat{x}$) bölgesel kaliteyi belirlemesi için Denklem (3.25)'de

verilen yapısal benzerlik metriği denkleminde kullanılır. Elde edilen sonuç değeri her bir parçanın nitelik puanıdır. Görüntünün tüm parçalarının puanları toplanıp, ortalaması hesaplanarak görüntünün kendisi için kalite metriği elde edilmiş olur.

$$\text{S}(\{x_k\},y) = \frac{2\sigma_{\hat{x}y}+C}{\sigma_{\hat{x}}^2+\sigma_y^2+C} \tag{3.25}$$

Burada x ve y seçilen parçalar, $\sigma_{\hat{x}}^2$, σ_y^2 ve $\sigma_{\hat{x}y}$ sırasıyla $\hat{x}$, y, ve $\hat{x}$ ile y arasındaki lokal varyanstır. C sabit bir değerdir.

Doku, benzersiz bir tür görsel sinyaldir ve yaygın olarak kabul edilen bir tanıma

sahip değildir (Zhai ve ark., 2013). Ancak genel olarak doku görüntüleri uzamsal olarak homojendir ve tekrarlanan öğelerden oluşur, genellikle konumlarında, boyutlarında, renklerinde, yönlerinde ve benzeri şeylerde bazı değişikliklere tabidir (Portilla ve ark., 2000). Genel olarak ifade etmek gerekirse, bir doku tekrarlayan düz bölgeler ve bunlar arasında geçiş bölgeleri, yani kenarlar içerir (Zhai ve ark., 2013). Bu pürüzsüz bölgelerin boyutları doku öğelerinin tekrarlayan yapılarını etkiler ve çevrelerindeki kenarlar dikkate alınarak yakalanabilir. Kenarlar arası mesafe olarak adlandırabilinen iki bitişik kenar arasındaki mesafe iyi bir özelliktir. Stokastiklik nedeniyle, kenarlar arası mesafeler sabit değildir, ancak böyle bir dağılım vardır. Ayrıca kenarlar arası mesafe dağılımları açıyla değişebilir ve bu tür varyasyonlar, dokuyu karakterize etmede anahtar olabilir. Benzer şekilde, en yakın kenarlara olan mesafelerin dağılımlarını yakalamak için LRI'nın başka versiyonu da mevcuttur. Her piksel için sekiz tamsayı yönlendirmesi veren, her biri bir yöne karşılık gelen iki LRI operatörü vardır. Sonra her yön için, karşılık gelen yönün histogramı hesaplanılır. Sekiz histogramın tamamının toplanması görüntü için bir LRI özellik vektörü veya istatistiği olarak kabul edilir.

NSER'deki kenar noktalarının sayısının değişimi görüntü kalitesini ölçmek için kullanılır (Zhang ve ark., 2011). Farklı görüntülerdeki farklı içerikler dikkate alınarak, NSER'deki kenar noktalarının sayısı referans görüntüdekilerle normalize edilmelidir. Böylece NSER metriği oluşturulur. Bu metrik dört adımdan oluşmaktadır.

Adım 1) Verilen referans (C) ve bozuk(D) görüntüler için farklı ölçekler üzerinde σi denklem 3.26'da tanımlanan LOG filtresi sırasıyla C_i ve $D_i(1 \leq i \leq N)$ çıktılarını üretmek için uygulanır.

Adım 2) Denklem 3.27'ye göre tüm N ölçeklerindeki C_i ve D_i'deki sıfır-geçiş belirlenerek kenar noktaları tanımlanır ve herbir ölçekte σi, C_i ve D_i'deki kenarları belirlemek için aynı eşik değeri T H_i kullanılır.

Adım 3) σi ölçeğindeki NSE haritası $E_{C_i} \cap E_{D_i}$ tarafından tanımlanır. $\|.\|$ operatörü NSE haritasındaki kenar noktalarının sayısını sayar. P_i tarafından tanıtılan

C_i ve D_i arasındaki benzerlik ölçme oranı şöyledir:

$P_i=||E_{C_i} \cap E_{D_i}||/||E_{C_i}||$

P_i aralığı [0,1] 'dir. P_i değeri yükseldikçe iki kenar haritasının benzerliği de artar.

Bozulma bozuk görüntünün değeriyle ilgilidir.

Adım 4) 1-p_i tüm ölçeklerde genel ölçümleri vermek için ürünleri tarafından birleştirilir. Subjektif skora bağlı doğrusal korelasyonu geliştirmek için logaritmik

fonksiyon kullanılmaktadır. Bu fonksiyon şöyledir:

$$NSER(C,D)= -\sum_{i=1}^{N} \log_{10}(1 - pi) \text{ 'dir.}$$

$$\nabla^2 G(x,y,\sigma)=\frac{1}{\pi\sigma^4}\left[1-\frac{x^2+y^2}{2\sigma^2}\right]\exp\left(\frac{x^2+y^2}{2\sigma^2}\right) \quad (3.26)$$

$$NSE(C,D)=E_C \cap E_D \quad (3.27)$$

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu bölümde önerilen farklı dikkat mekanizmalarının düşük aydınlıklı görüntü iyileştirme üzerindeki etkileri yönteminin başarımı araştırmak için yapılan deneyler ve elde edilen bulgular verilmektedir. Öncelikle önerilen yöntemin performansı, SSIENet yöntemiyle sayısal ve görsel olarak karşılaştırılmıştır. Ardından önerilen farklı yöntemlerin birbirlerine göre durumları karşılaştırılmıştır.

4.1. Önerilen Yöntemin Sayısal Karşılaştırılması

SSIENet düşük aydınlıklı görüntü geliştirme çalışmasından yola çıkarak ve dikkat mekanizmalarının bilgisayarlı görüdeki başarısı göz önüne alınarak SSIENet'e dikkat mekanizması eklenerek önerilen hibrit yaklaşımın başarısı incelenmiştir. Önerdiğimiz yöntemi sıklıkla kullanılan dikkat mekanizmalarıyla etkisini ölçtük. Oluşturmuş olduğumuz mimari yapısında kullandığımız dikkat mekanizmalarını SSIENet'in farklı katmanlarının farklı yerlerine ekleyerek çeşitli uygulamalar yapılmıştır. En iyi sonucu aldığımız katmanların bulunduğu mimari yapımız Çizelge 4.1'de gösterilmiştir.

Tez kapsamında önerilen Farklı dikkat mekanizmalarının düşük aydınlıklı görüntü iyileştirme üzerindeki etkileri literatürde iyi bilinen kalite metrikleri yardımıyla karşılaştırılmıştır. Çizelge 4.2 literatürde var olan ve ilham alınan SSIENet yönteminin ve SSIENet yönteminin deneme yanılma yoluyla en iyi sonucu aldığımız katmanlarına bırakılan dikkat mekanizmaları ile beraber elde ettiğimiz PSNR, SSIM, LRI ve NSER metrik sonuçlarını göstermektedir.

Çizelge 4.2'de görüleceği üzere SSIENet yöntemi PSNR metriğine göre uygulamış olduğumuz farklı dikkat mekanizmalarında sadece darboğaz dikkat mekanizmasına göre çok az bir farkla daha büyük sonuç üretmiştir. Diğer uygulamış olduğumuz kanal, etkili kanal, uzamsal ve kanal sıkma ve uyarma, koordinat, sıkma ve uyarma dikkat ağlarına göre çok daha fazla bir sayısal farkla daha başarısız sonuçlar üretmiştir.

Değerlendirilen düşük aydınlıklı görüntü iyileştirme yöntemlerinin karşılaştırıldığı bir diğer metrik olan SSIM metriği için sonuçlarda Çizelge 4.2'de verilmiştir. Çizelge incelendiğinde görüleceği üzere PSNR metriğinin aksine SSIENet'e eklenen altı farklı dikkat mekanizmasıyla da ürettiği sonuçlar SSIENet çalışmasına göre açık ara farkla daha yüksektir. Ancak görüldüğü üzere hem PSNR hem de SSIM metrik sonuçlarına göre en iyi başarımı sıkma ve uyarma dikkat ağında elde etmiştir.

Çizelge 4. 1. En iyi sonucu veren dikkat mekanizmalarının katman sıralama yapısı

Girdiler	Çıktı Kanal	Çıktı İsim
RGB&maxR,G,B	32	Conv0
RGB&maxR,G,B	64	Conv
Conv	64	Conv1
Attention	64	Att
Conv1	128	Conv2
Attention	128	Att
Conv2	128	Conv3
Conv3	64	Conv4
Conv4&Conv1	128	Con5
Attention	128	Att
Conv5	64	Conv6
Conv6&Conv0	96	Conv7
Attention	96	Att
Conv7	64	Conv8
Conv8	4	Conv9
Attention	4	Att
Conv9	4	R&I

Çizelge 4.2. Farklı dikkat mekanizmalarının, Histogram eşitlemenin ve SSIENet görüntülerinin PSNR , SSIM, LRI ve NSER performans kıyaslaması

Metodlar	PSNR↑	SSIM↑	LRI↑	NSER↑
Histogram Eşitleme	13.5749	0.4019	0.8024	0.7916
SSIENet	19.1574	0.7108	0.8237	0.9069
SSIENet+Koordinat Dikkat	19.3872	0.7458	0.8133	0.9092
SSIENet+Darboğaz Dikkat	19.0952	0.7328	0.8164	0.9110
SSIENet+Kanal Dikkat	19.5317	0.7573	0.8184	0.9022
SSIENet+Uzamsal ve Kanal Sıkmave Uyarma Dikkat	19.6083	0.7554	0.8179	**0.9143**
SSIENet+Etkili Kanala Dikkat	20.0530	0.7467	0.8228	0.9035
SSIENET+Sıkma ve Uyarma Dikkat	**20.5135**	**0.7657**	**0.8237**	0.9100

4.2. Önerilen Yöntemin Görsel Karşılaştırılması

Kullanılan dikkat mekanizmalarının birbirlerine göre ve ayrıca SSIENet yöntemine göre görsel kıyaslamaları bu bölümde karşılaştırılmaktadır.

Şekil 4.1'de girdi görüntü, SSIENet, uygulanan altı dikkat mekanizma ve referans görüntü örneklerinden bir tanesi verilmiştir. Şekil 4.1.(b) SSIENet görüntüsünün üst orta tarafı olan labutların üstündeki uçan balon görüntüleri (c),(d),(e),(f),(g),(h)ve (ı) görüntüleri olan dikkat mekanizmalı yöntemlerle elde edilmiş görüntülere göre daha soluk renklere sahiptir. Şekil 4.1(b)'de sağ duvardaki resmin anlaşılırlığı ve netliği dikkat mekanizmalı yöntemlerin sonuç görüntülerine göre daha düşüktür. Şekil 4.1(b)'deki yer yüzeyinde bowlingin atıldığı yüzey ve bowlingi atan atıcının bulunduğu yüzeydeki gürültü dikkat mekanizmalı yöntemlerin sonuç görüntülerine göre daha fazla gürültü içermektedir.

Şekil 4.1'de bulunan (c),(d),(e),(f),(g),(h)ve (ı) görüntüleri olan kullanılan farklı dikkat mekanizmalarının birbirlerine göre durumlarına bakılırsa, referans görüntünün renk kalitesine neredeyse ulaşan (f) görüntüsü olan kanal dikkat mekanizması renk başarısıyla diğer dikkat mekanizmalarını geride bırakmıştır. Bu başarı hem uçan balonlara hem de yer yüzeyine bakıldığında net bir şekilde görülmektedir. Yer yüzeyinin bowling atıcısını bulunacağı kısmına bakılırsa (h) görüntüsü olan koordinat dikkat mekanizmasında gürültünün diğer dikkat mekanizmalı görüntülere göre daha fazla giderildiği görülmektedir. Şekil 4.1 (e) görüntüsü olan uzamsal ve kanal sıkma ve uyarma dikkat ağının yüzeylerin belirginliğinde diğer dikkat mekanizmalarına göre üstünlük göstererek daha iyi dokuya sahip olduğu görülmektedir. Şekil 4.1 (c)'deki görüntü olan sıkma ve uyarma dikkat ağının yüzeydeki çizgiler göz önünde bulundurulduğunda diğer dikkat mekanizmalı görüntülere göre daha iyi kenar bilgisi elde ettiği gözlemlenmektedir.

Şekil 4.2'de başka bir görüntünün test sonuçları verilmiştir. Sırasıyla girdi, SSIENet, uygulanan dikkat mekanizmaları ve referans sonuçları gösterilmektedir. Her bir görüntünün sağ tarafındaki açık dolap kapısının içine bakıldığında dikkat mekanizmalarının SSIENet'e göre referans görüntünün kalitesine daha yakın olmasının yanı sıra ayrıca SSIENet'deki gürültüler dikkat mekanizmalarının sonuç görüntülerinde gözlemlenmemektedir. Şekil 4.2'deki görüntülerin sol dolabının şeffaf camları gözlemlendiğinde dikkat mekanizmalarının kalitesine SSIENet sonuç görüntüsünün erişemediği açık bir şekilde görülmektedir.

Şekil 4.2'nin dikkat mekanizmalarının birbirlerine göre durumları incelendiğinde (h) görüntüsü olan koordinat dikkat mekanizmasının diğer dikkat mekanizmalarına göre daha gürültüden ayıklanmış olduğunu açık dolabın ikinci rafı olan kaselerin üstüne bakılarak anlaşılabilir. Görüntülerdeki tencerelerin görüntü kalitesiyle de (f) görüntüsü olan kanal dikkatin diğer dikkat mekanizmalarına göre renk performansını referans görüntüye daha yaklaştığı gözlemlenmektedir.

Şekil 4.3 incelendiğinde görüntülerin sağ üst kısmındaki küçük kutucuklardan oluşan bölgede (b) görüntüsü olan SSIENet'de renklerin canlılığı dikkat mekanizmalı görüntülere göre daha az iken aynı zamanda gürültünün varlığı da dikkat

mekanizmalarına göre daha fazladır. Bunun yanı sıra sol taraftaki yastığın desenlerinin ayrıntıları dikkat mekanizmalı sonuç görüntülerinde SSIENet'e göre daha fazla oldu görülmektedir.

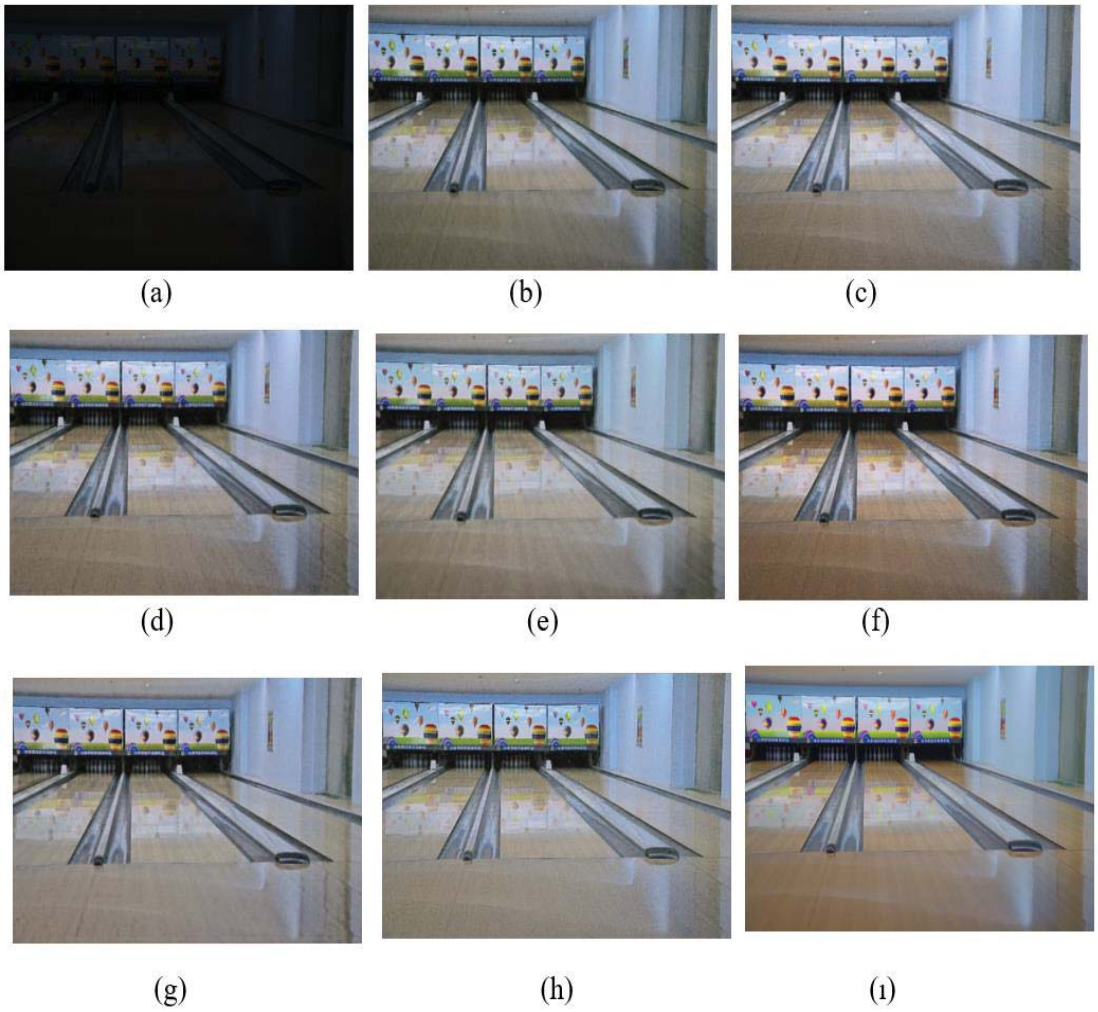
Şekil 4.3'deki dikkat mekanizmalı sonuç görüntülerinin birbirlerine göre durumları incelendiğinde (f) görüntüsü olan kanal dikkat mekanizmalı görüntünün referans görüntüsü olan (ı) görüntüsüne renk olarak diğer dikkat mekanizmalarından daha benzer olduğunu ayıcığın gövdesi olan yeşil renginden ve kutucukların renginden anlaşılabilmektedir. Şekil 4.3'deki görüntüleri soldaki yastık kılıfının detayları incelendiğinde (e) görüntüsü olan uzamsal ve kanal sıkma ve uyarma dikkat ağının doku olarak diğer dikkat mekanizmalarından daha başarılı olduğu görülebilmektedir.

Şekil 4.4'deki görüntüler değerlendirildiğinde (b) görüntüsü olan SSIENet'deki dolabın içindeki yazıcıda görünen gürültülerin diğer dikkat mekanizmalı görüntülerde yok olduğu görülmektedir. Şekil 4.4'deki görüntülerde bulunan dolabın rafında bulunan etiketin rengi (b) görüntüsündeki SSIENet'inkine göre dikkat mekanizmalı görüntülerinin rengi (ı) görüntüsü olan referans görüntüye daha yakın olduğu gözlemlenmektedir.

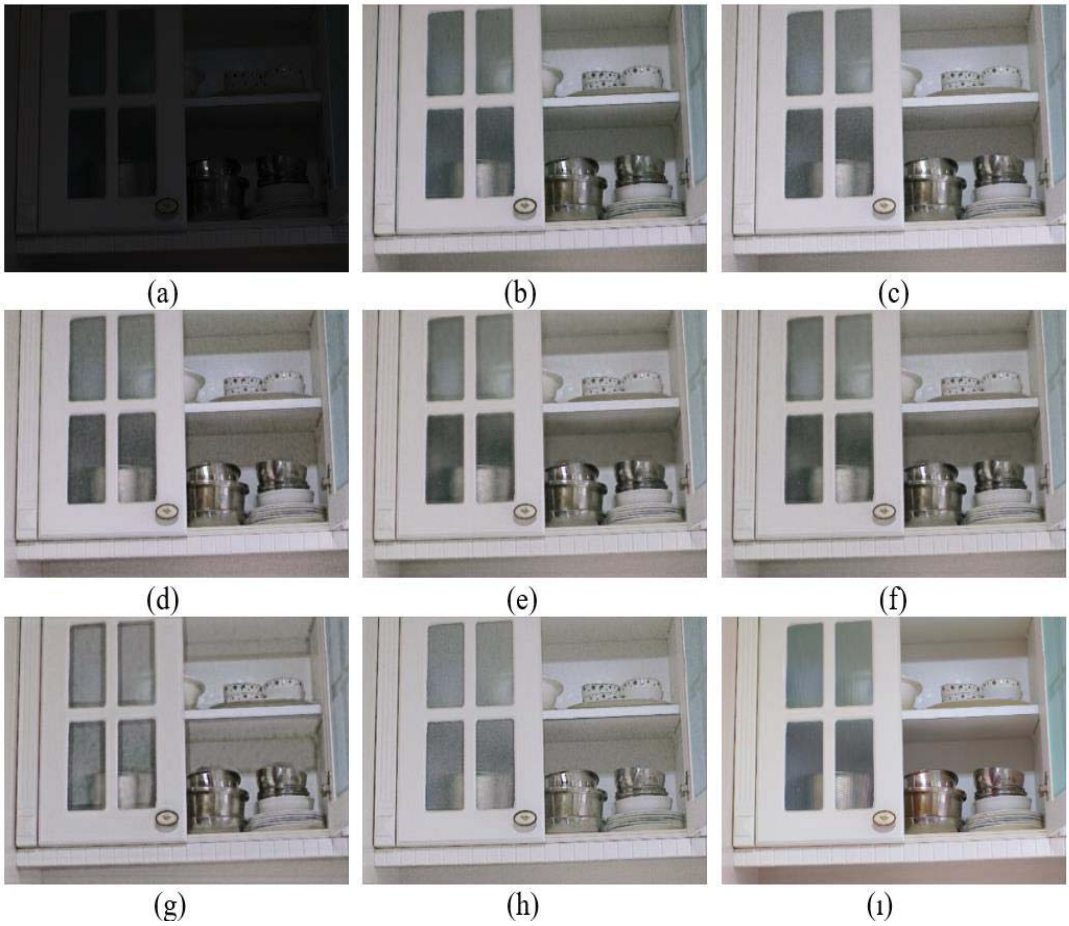
Şekil 4.4'de olan (c),(d),(e),(f),(g) ve (h) görüntüleri olan dikkat mekanizmalı görüntülerin birbirlerine göre durumlarına bakıldığında (e) görüntüsü olan uzamsal ve kanal sıkma ve uyarma dikkat ağının görüntüsünün doku olarak diğer dikkat mekanizmalı görüntülerden daha iyi olduğu görülmektedir. Dolap kenarları açısından da (c) görüntüsü olan sıkma ve uyarma dikkat ağının diğer dikkat mekanizmalı görüntülerden daha iyi olduğu fark edilmektedir.

Şekil 4.5'de her bir satır sırasıyla düşük aydınlıklı giriş görüntüleri, SSIENet, Sıkma ve Uyarma, Etkili Kanal, Uzamsal ve Kanal Sıkma ve Uyarma, Kanal, Darboğaz, Koordinat Dikkat mekanizmaları ve Referans çıktı görüntüleri verilmiştir. Buradaki görüntüler birinci satırdaki girdi görüntülerde kutucuk içine alınan kısımların büyütülmüş halidir. İlk sütunlara bakıldığında hem duvardaki hem de kapıdaki gürültüleri en iyi temizleyenin Koordinat dikkat mekanizmasında gerçekleştiği gözlemlenmektedir. İkinci sütundaki görüntüler incelendiğinde ground truthun renk kalitesine en iyi ulaşmış olan dikkat mekanizması Kanal dikkat olmuştur. Üçüncü

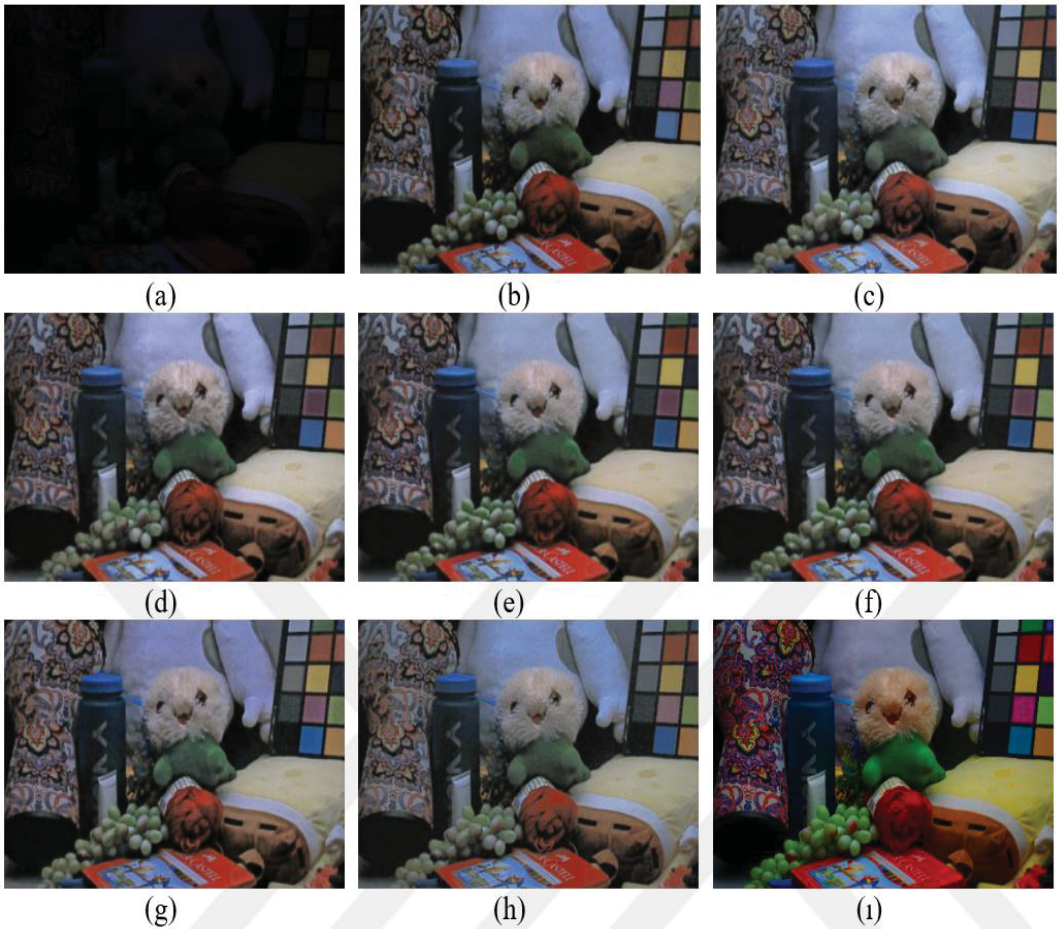
sütunda bulunan dijital saatin kenarı incelendiğinde en iyi kenar geliştirmeyi Sıkma ve Uyarma dikkat mekanizması sağlamıştır. İkinci sütundaki yer yüzeyinin belirginliğinin değerlendirilmesinde Uzamsal ve Kanal Sıkma ve Uyarma dikkat mekanizmasının diğer dikkat mekanizmalarına göre daha iyi dokuya sahip olduğu gözlemlenmiştir.



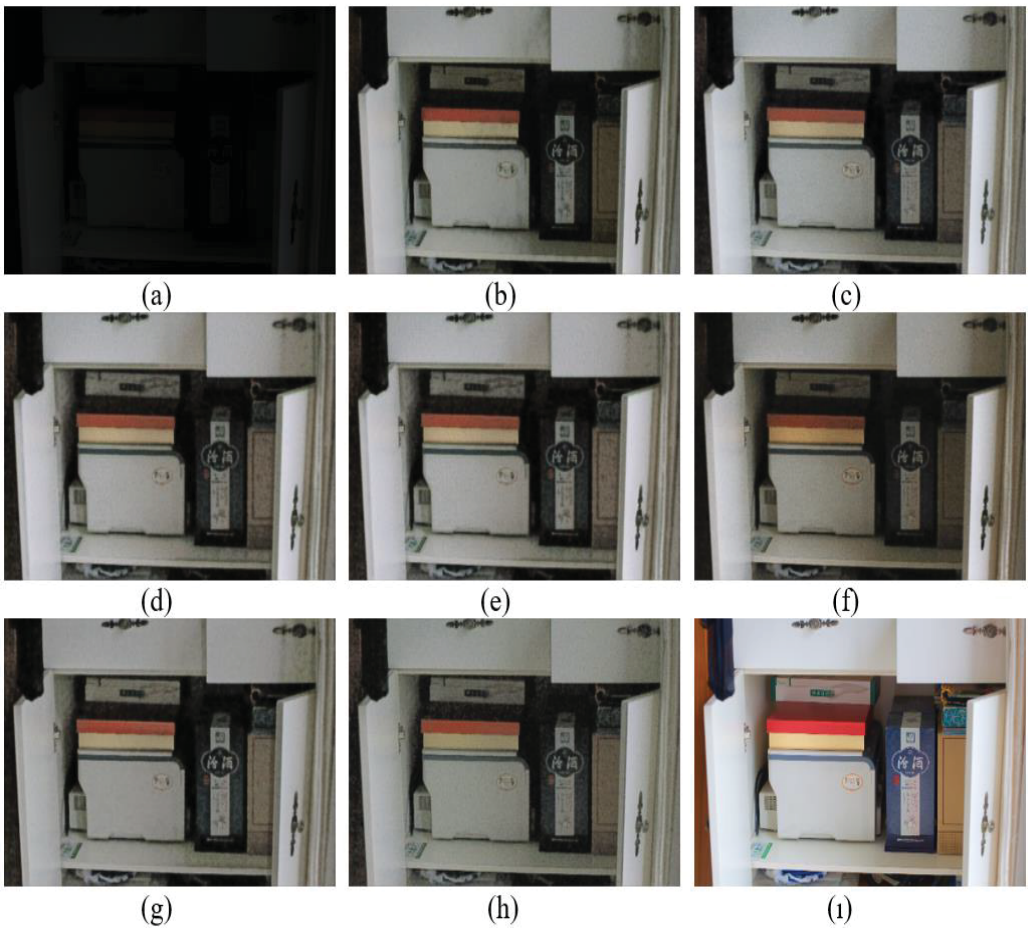
Şekil 4.1. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans



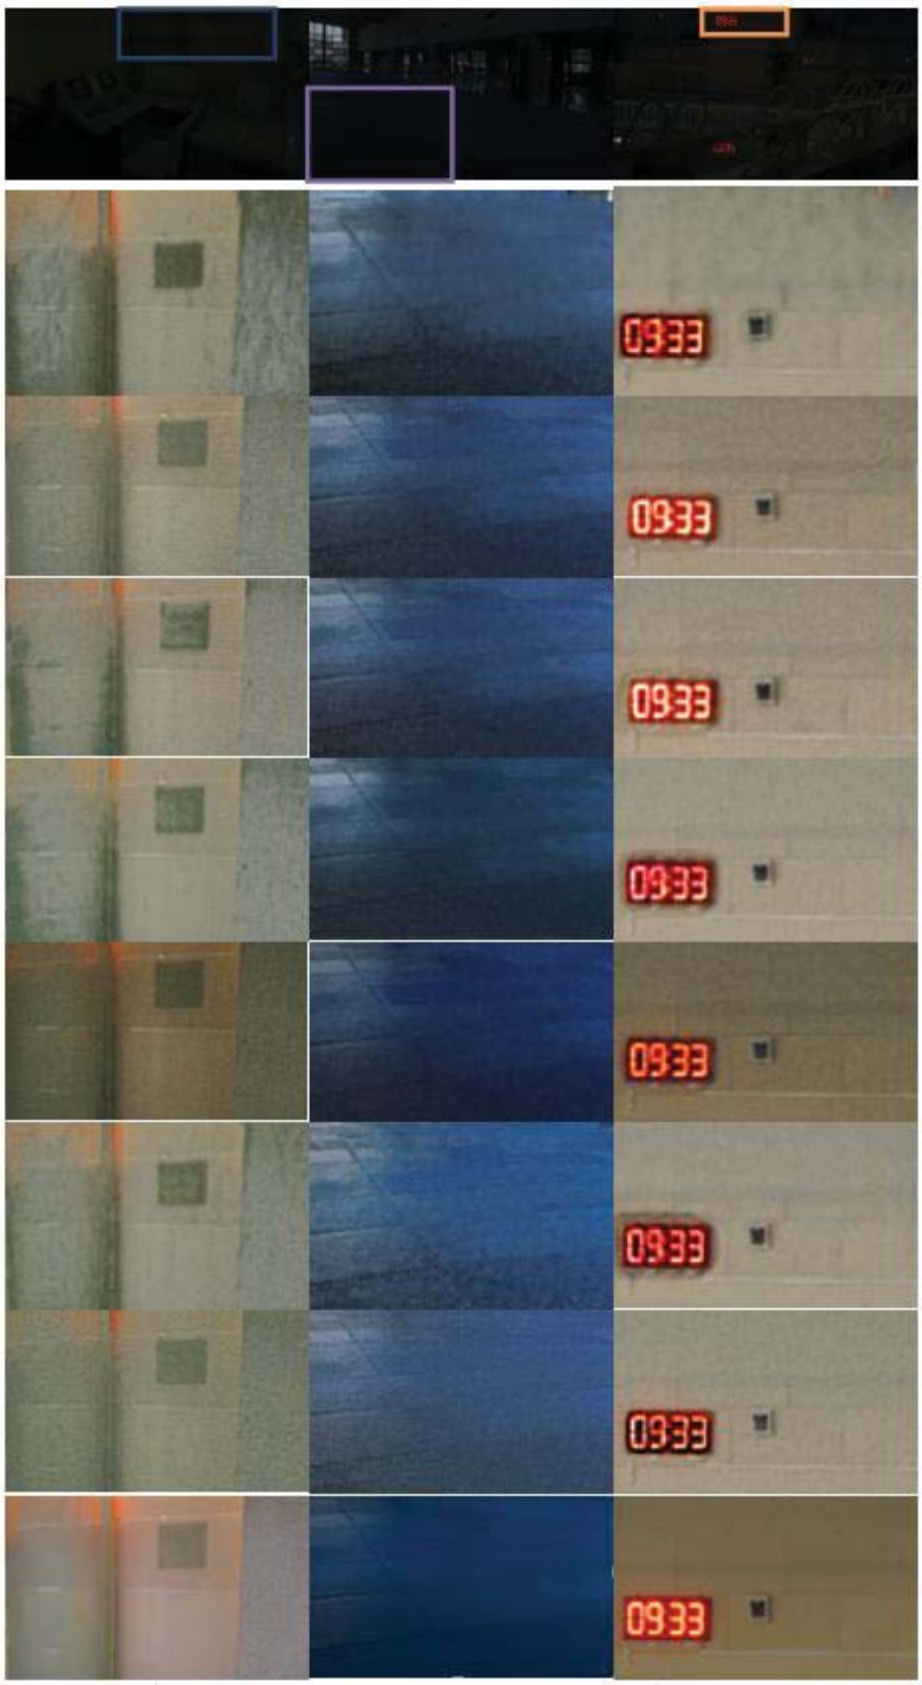
Şekil 4.2. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans



Şekil 4.3. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans



Şekil 4.4. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans



Şekil 4.5. (a)Girdi görüntü (b)SSIENet (c)Sıkma ve Uyarma (d)Etkili Kanal (e)Uzamsal ve Kanal Sıkma ve Uyarma (f)Kanal (g)Darboğaz (h)Koordinat (ı)Referans



Şekil 4.6. Cep telefonuyla çekilmiş görüntünün test sonuçları (a)Girdi görüntü (b)Histogram Eşitleme (c)SSIENet (d)Sıkma ve Uyarma (e)Etkili Kanal (f)Uzamsal ve Kanal Sıkma ve Uyarma (g)Kanal (h)Darboğaz (ı)Koordinat

4.3. Tartışma

Bu tez çalışmasında altı farklı dikkat mekanizmasının düşük aydınlıklı görüntü iyileştirme üzerindeki etkileri ortaya konmuştur. Dikkat mekanizmalarının doğal dil işlemedeki olağanüstü başarısından sonra, bilgisayarlı görü çalışmalarında da geldiği noktadan ilham alarak düşük aydınlıklı görüntü geliştirme çalışmalarında da bu başarıya ulaşabilineceği kanaatiyle en çok kullanılan dikkat mekanizmaları seçilerek hem düşük aydınlıklı görüntü geliştirme sağlanıp hem de farklı dikkat mekanizmalarının birbirlerine göre performansları gözlemlenmiştir.

Sıkma ve uyarma dikkat ağı bilgisayarlı görü de en çok kullanılan olarak seçilmiş olup ve en iyi performans da sıkma ve uyarma dikkat mekanizmasından elde edilmiştir. Giriş görüntüsüne uyguladığı dönüşümün ardından tüm kanallar üzerinden çıktıyı toplama ile ürettiğinden ötürü en iyi başarıyı göstermektedir. Sıkma ve uyarma ağının kanallar arası etkileşimi arttırılıp sıkma ve uyarmadaki boyut azaltmanın görüntülerde oluşturduğu tahripten ötürü boyut azaltma olmaksızın çalışmasını sürdüren etkili kanal dikkat mekanizması bu yöntemleri sayesinde ikinci en iyi başarıma ulaşmıştır. Üçüncü en iyi performansı gösteren uzamsal ve kanal sıkma ve uyarma dikkat ağı kanal bazlı ve uzamsal giriş özelliğini eş zamanlı olarak yeniden kalibre ederek bu başarımı sağlamıştır. Hem uzamsal hem kanal yeniden ölçeklendirildiğinde daha yüksek önem elde edildiğinden ve giriş özellik haritası daha yüksek aktivasyon verildiğinden diğer dikkat mekanizmalarından daha iyi sonuç almıştır. Birçok çalışmada da çok fazla tercih edilmenin yanı sıra başarılar elde eden kanal dikkat mekanizması tüm kanallar üzerinde dikkat uygulayarak bu tez çalışmasında da dördüncü başarılı sırayı almıştır. Kullanılan dikkat mekanizmalarından koordinat dikkat mekanizması yatay ve dikey koordinatlarını kodlayıp iki havuz filtre kapsamı kullanarak beşinci başarılı performansı göstermektedir. Koordinat dikkat mekanizmasının mobil net çalışmalarındaki başarısı bu tez çalışmasında da durum değerlendirilmesinin yapılmasına yönlendirmiştir. Darboğaz dikkat mekanizması kullanılan diğer dikkat mekanizmalarına göre en düşük başarımı sağlamıştır. Darboğaz dikkat mekanizmasının bu performansı kullandığı uzamsal dikkat mekanizmasının içerisindeki genişletilmiş evrişimden kaynaklandığı düşünülmektedir.

Darboğaz dikkat mekanizmasıyla ilham alınan SSIENet'e göre PSNR metriği sonucu daha düşük sayısal başarı elde edilmiş olmasına rağmen SSIM ve NSER metriklerine göre başarılı sonuçlar elde edilmiştir. PSNR metriği genel bir değerlendirme metriği olması nedeniyle sadece kenar değerlendirmesi yapan NSER metriğiyle Darboğaz dikkat mekanizmasının kenar iyileştrime amacı olan çalışmalara hibrit çalışma olarak entegre edilebilmesi durumunda katkı sunacağı görülmektedir.

LRI metriğiyle yapılan dokusal değerlendirmeyle ilham alınan SSIENet'e göre başarılı sonuçlara ulaşılamamıştır. NSER kenar metriği sayısal sonuçlarında da görüldüğü üzere başka spesifik alanlarda elde edilen başarılı sonuçlar kullanılan dikkat mekanizmalarının farklı alanlara yöneldiğini göstermektedir.

Elde edilen sayısal sonuçlara göre sadece kanal dikkat ve etkili kanal dikkat mekanizmaları başarılı sonuçlar elde edememiştir. Kanal dikkat ve etkili dikkat mekanizmaları çalışma yoğunluğunu tüm kanallar üzerinde gerçekleştirdiğinden kaynaklandığı düşünülmektedir.

5. SONUÇLAR ve ÖNERİLER

Bu çalışma düşük aydınlıklı görüntü geliştirmenin dikkat mekanizmalarının eklenmesiyle girdi görüntülerin iyileşerek daha iyi sonuçlara ulaşılmasını amaçlamaktadır. Altı farklı dikkat mekanizması kullanılarak her birinin ayrıca birbirlerine göre durumları da analiz edilmiştir. Önerilen yöntemde kullanılan dikkat mekanizmaları birbirleriyle ve ilham alınan yöntemle sayısal ve görsel olarak karşılaştırılmıştır. Tez çalışmasında ortaya konan yöntemlerin yapılan sayısal ve görsel karşılaştırmalar sonucunda yapılan değerlendirmede, ilham alınan literatürdeki yöntemden daha iyi sonuç ortaya koyduğu belirlenmiştir. Ayrıca altı farklı dikkat mekanizmasının birbirlerine göre farklı başarı oranları göserdikleri tespit edilmiştir. Özellikle görsel sonuçlar önerilen yöntemdeki kullanılan farklı dikkat mekanizmalarının kaynak görüntüdeki detayları muhafaza eden, yüksek renk doygunluğuna sahip, gürültülerden olabildiğince arındırılmış görüntüler ürettiğini göstermektedir. Değerlendirmede kullanılan sayısal metrikler de önerilen yöntemin ilham alınan yöntemden daha başarılı sonuçlar ortaya koymanın yanı sıra, bu metrikler altı farklı dikkat mekanizmalarının birbirlerine göre başarı durumunu da sunmuştur. Ayrıca literatür de en çok kullanılan ve başarısı en yüksek olan dikkat mekanizmaları ve farklı dallarda kullanılan dikkat mekanizmaları da entegre edilerek literatüre hangi dikkat mekanizması kullanılırsa daha başarılı sonuçlar üretilebileceği öngörüsü de sunulmuştur.

Yapılan değerlendirmelerde görsel sonuçların başarılı performansını desteklemek için sayısal analizde gerçekleştirilmiştir. Bu durumda da önerilen yöntemlerin daha yüksek başarımlar yakaladığı sonucuna ulaşılmıştır. Bulduğumuz sayısal değerlere ve görsel sonuçlara ulaşabilmek için çeşitli katmanlar arasına dikkat mekanizmaları eklenerek eğitim ve testler yapılmıştır. En iyi başarı elde edildikten sonra dikkat meknizmalarının entegrasyonunun yapıldığı konumun mimari yapısı sunulmuştur.

Kullanılan sayısal değerlendirme ölçütleriyle yapılan çalışmanın literatürdeki çalışmaya göre daha başarılı olduğu gösterilirken aynı zamanda altı farklı yönteminde birbirlerine göre başarımı nicel olarak gösterilmiştir. Ayrıca literatürde

hesaplanılmayan özellikle kenar ve dokusal olarak başarım oranını gösteren metrikler de tercih edilmiştir. Böylece hangi dikkat mekanizmasının kenar geliştirmede hangi dikkat mekanizmasının dokusal olarak geliştirmede daha başarılı olduğunu sayısal olarak gözler önüne sermektedir. Bu çalışma normalde kullanılan değerlendirme ölçütlerinin yanı sıra spesifik değerlendirme ölçütleri olan LRI (dokusal) ve NSER (kenar) ile bir yöntemin spesifik bir başarımının nasıl olabileceğini de literarüre kazandırmıştır.

Tez kapsamında yürütülen çalışmalar sonucunda önerilen yöntemin geliştirilmeye açık olduğu görülmektedir. Yapılan çalışmada Retineks teorisi, evrişimsel sinir ağları ve dikkat mekanizmaları birlikte kullanılarak her ne kadar iyileştirme yapılmış olunsa da referans görüntüye ulaşması için önerilen ve mevcut yöntemlerin geliştirilmeye devam edilmesi gerektiği görülmektedir. Bunun için bu kuvvetli entegre yöntemlere başka mimariler eklenebilir veya kullanılan bu yöntemlerin yerine yine bu yöntemlerin amacında çalışan fakat performansı daha ileriye götürecek yöntemler araştırılıp eklenerek geliştirilebilir.

Gelecek çalışmada farklı mimarilerinin entegrasyonun yanı sıra spesifik başka değerlendirme ölçütleri de kullanılabilir. Bu çalışmadaki görsel sonuçların ortaya koyduğu değerlendirmeye göre kullanılan dikkat mekanizmaları gürültü gidermede başarılı sonuçlar üretmiştir.

KAYNAKLAR

ABDULLAH-AL-WADUD, M. and KABİR, H., MD., Ali AKBER DEWAN, M. and CHAE, O., 2007. *A dynamic histogram equalization for image contrast enhancement, IEEE Transactions on Consumer Electronics*, *53*(2):593-600.

BAHDANAU, D., CHO, K. and BENGİO, Y., 2014. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*.

BASTİDAS, A.A. and TANG, H., 2019. Channel attention networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 0-0).

CAİ, J., GU, S. and ZHANG, L., 2018. Learning a deep single image contrast enhancer from multi-exposure images. *IEEE Transactions on Image Processing*, *27*(4): 2049-2062.

CHEN, Y. K., CHENG, F. C. and TSAİ, P., 2011. A gray-level clustering reduction algorithm with the least PSNR. *Expert Systems with Applications*, *38*(8): 10183-10187.

CHEN, Z., LİANG, Y. and DU, M., 2022. Attention-based Broad Self-guided Network for Low-light Image Enhancement. In *2022 26th International Conference on Pattern Recognition (ICPR)*:31-38.

DABOV, K., FOİ, A., KATKOVNİK, V. and EGİAZARİAN, K., 2006. Image denoising with block-matching and 3D filtering, In *Image processing: algorithms and systems, neural networks, and machine learning* Vol. 6064: 354-365.

DANG-NGUYEN, D.T., PASQUİNİ, C., CONOTTER, V. and BOATO, G., 2015. Raise: A raw images dataset for digital image forensics. In *Proceedings of the 6th ACM multimedia systems conference*: 219-224.

FENG, Z. and HAO, S., 2017. Low-light image enhancement by refining illumination map with self-guided filtering, In *2017 IEEE International Conference on Big Knowledge (ICBK):* 183-187.

GÓMEZ, P., SEMMLER, M., SCHÜTZENBERGER, A., BOHR, C. and DÖLLİNGER, M., 2019. Low-light image enhancement of high-speed endoscopic videos using a convolutional neural network. *Medical & biological engineering & computing*, *57*:1451-1463.

GUO, C., Lİ, C., GUO, J., LOY, C.C., HOU, J., KWONG, S. and CONG, R., 2020. Zero-reference deep curve estimation for low-light image enhancement, In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition:*1780-1789.

GUO, X., Lİ, Y. and LİNG, H., 2016. LIME: Low-light image enhancement via illumination map estimation, *IEEE Transactions on image processing*, *26*(2):982-993.

HAO, S., FENG, Z. and GUO, Y., 2018. Low-light image enhancement with a refined illumination map, *Multimedia Tools and Applications*, *77*:29639-29650.

HAO, S., HAN, X., GUO, Y., XU, X. and WANG, M., 2020. Low-light image enhancement with semi-decoupled decomposition, *IEEE transactions on multimedia*, *22*(12):3025-3038.

HAO, W., YE, Z., HONG-HAİ, S. and JİNG-ZHONG, Z., 2017. Review of image enhancement algorithms. *Chinese Optics*, *10*(4):438-448.

HOU, Q., ZHOU, D. and FENG, J., 2021. Coordinate attention for efficient mobile network design, In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*:13713-13722.

HU, J., SHEN, L. and SUN, G., 2018. Squeeze-and-excitation networks, In *Proceedings of the IEEE conference on computer vision and pattern recognition*:7132-7141.

JİANG, Y., GONG, X., LİU, D., CHENG, Y., FANG, C., SHEN, X., YANG, J., ZHOU, P. and WANG, Z., 2021. Enlightengan: Deep light enhancement without paired supervision, *IEEE transactions on image processing*, *30*:2340-2349.

KATIRCIOĞLU, F. (2021). Düşük-Işıklı Renkli Görüntülerin İyileştirilmesinde Kullanılan Retineks Algoritmalarının Karşılaştırmalı Analizi, *Mühendislik Bilimleri ve Araştırmaları Dergisi*, *3*(2):188-206.

KİM, B., LEE, S., KİM, N., JANG, D. and KİM, D.S., 2022. Learning color representations for low-light image enhancement, In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*:1455-1463.

LEE, C., LEE, C. and KİM, C.S., 2013. Contrast enhancement based on layered difference representation of 2D histograms, *IEEE transactions on image processing*, *22*(12):5372-5384.

LEE, H.G., YANG, S. and SİM, J.Y., 2015. Color preserving contrast enhancement for low light level images based on Retinex, In *2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)*:884-887.

Lİ, L., SUN, S., XİA, C., CHEN, P. and DONG, F.M., 2014. Survey of histogram equalization technology, *Comput. Syst. Appl*, *23*(3):1-8.

Lİ, L., WANG, R., WANG, W. and GAO, W., 2015. A low-light image enhancement method for both denoising and contrast enlarging, In *2015 IEEE international conference on image processing (ICIP)*:3730-3734.

Lİ, M., LİU, J., YANG, W., SUN, X. and GUO, Z., 2018. Structure-revealing low-light image enhancement via robust retinex model, *IEEE Transactions on Image Processing*, *27*(6):2828-2841.

LİANG, D., Lİ, L., WEİ, M., YANG, S., ZHANG, L., YANG, W., DU, Y. and ZHOU, H., 2022. Semantically contrastive learning for low-light image enhancement, In *Proceedings of the AAAI Conference on Artificial Intelligence* Vol. 36, No. 2:1555-1563.

LİM, J., HEO, M., LEE, C. and KİM, C.S., 2017. Contrast enhancement of noisy low-light images based on structure-texture-noise decomposition, *Journal of Visual Communication and Image Representation*, *45*:107-121.

LİU, H., SUN, X., HAN, H. and CAO, W., 2016. Low-light video image enhancement based on multiscale retinex-like algorithm, In *2016 Chinese Control and Decision Conference (CCDC)*:3712-3715.

LORE, K.G., AKİNTAYO, A. and SARKAR, S., 2017. LLNet: A deep autoencoder approach to natural low-light image enhancement, *Pattern Recognition*, *61*:650-662.

LU, K. and ZHANG, L., 2020. TBEFN: A two-branch exposure-fusion network for low-light image enhancement, *IEEE Transactions on Multimedia*, *23*:4093-

4105.
LV, F., Lİ, Y. and LU, F., 2021. Attention guided low-light image enhancement with a large scale low-light simulation dataset, *International Journal of Computer Vision*, *129*(7):2175-2193.
M. KİM, D. PARK, D. K. HAN and H. KO, 2014. A novel framework for extremely low-light video enhancement, *2014 IEEE International Conference on Consumer Electronics (ICCE)*:91-92.
MA, K., ZENG, K. and WANG, Z., 2015. Perceptual quality assessment for multi-exposure image fusion, *IEEE Transactions on Image Processing*, *24*(11):3345-3356.
PANETTA, K., AGAİAN, S., ZHOU, Y. and WHARTON, E.J., 2010. Parameterized logarithmic framework for image enhancement, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, *41*(2):460-473.
PARK, J., WOO, S., LEE, J.Y. and KWEON, I.S., 2018. Bam: Bottleneck attention module. *arXiv preprint arXiv:1807.06514*.
PARK, S., YU, S., MOON, B., KO, S. and PAİK, J., 2017. Low-light image enhancement using variational optimization-based retinex model, *IEEE Transactions on Consumer Electronics*, *63*(2):178-184.
PEİ, S.C. and SHEN, C.T., 2017. Color enhancement with adaptive illumination estimation for low-backlighted displays, *IEEE Transactions on Multimedia*, *19*(8):1956-1961.
PORTİLLA, J. and SİMONCELLİ, E.P., 2000. A parametric texture model based on joint statistics of complex wavelet coefficients, *International journal of computer vision*, *40*:49-70.
QU, Y. and OU, Y., 2020. LEUGAN: low-light image enhancement by unsupervised generative attentional networks, *arXiv preprint arXiv:2012.13322*.
REN, W., LİU, S., MA, L., XU, Q., XU, X., CAO, X., DU, J. and YANG, M.H., 2019. Low-light image enhancement via a deep hybrid network, *IEEE Transactions on Image Processing*, *28*(9):4364-4375.
ROY, A.G., NAVAB, N. and WACHİNGER, C., 2018. Concurrent spatial and channel 'squeeze & excitation'in fully convolutional networks, In *Medical Image Computing and Computer Assisted Intervention–MICCAI 2018: 21st International Conference, Granada, Spain, September 16-20, 2018, Proceedings, Part I* :421-429.
SHEN, L., YUE, Z., FENG, F., CHEN, Q., LİU, S. and MA, J., 2017. Msr-net: Low-light image enhancement using deep convolutional network, *arXiv preprint arXiv:1711.02488*.
SRİNİVAS, K. and BHANDARİ, A.K., 2020. Low light image enhancement with adaptive sigmoid transfer function, *IET Image Processing*, *14*(4):668-678.
SRİVASTAVA, N., HİNTON, G., KRİZHEVSKY, A., SUTSKEVER, I. and SALAKHUTDİNOV, R., 2014. Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, *15*(1):1929-1958.
SUN, S., DONG, Y. and TANG, C., 2018. An enhanced algorithm for single nighttime low illuminated vehicle-mounted video image, *Computer Technology and Development*, *28*(4):50-54.

TANAKA, M., SHİBATA, T. and OKUTOMİ, M., 2019. Gradient-based low-light image enhancement, In *2019 IEEE International Conference on Consumer Electronics (ICCE)*:1-2.

TAO, L., ZHU, C., XİANG, G., Lİ, Y., JİA, H. and XİE, X., 2017. LLCNN: A convolutional neural network for low-light image enhancement, In *2017 IEEE Visual Communications and Image Processing (VCIP)*:1-4

TİAN, X., XU, X. and WU, C., 2015. Low illumination color image enhancement algorithm based on LIP model, *J. Xian Univ. Posts Telecommun.*, *20*(1):9-13.

WANG, J., 2018. An enhancement algorithm for low-illumination color image with preserving edge, *Comput. Technol. Develop.*, *28*(1):116-120.

WANG, L., FU, G., JİANG, Z., JU, G. and MEN, A., 2019. Low-light image enhancement with attention and multi-level feature fusion, In *2019 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*:276-281.

WANG, M., TİAN, Z., GUİ, W., ZHANG, X. and WANG, W., 2020. Low-light image enhancement based on nonsubsampled shearlet transform, *IEEE Access*, *8*:63162-63174.

WANG, Q., WU, B., ZHU, P., Lİ, P., ZUO, W. and HU, Q., 2020. ECA-Net: Efficient channel attention for deep convolutional neural networks, In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*:11534-11542.

WANG, S., ZHENG, J., HU, H.M. and Lİ, B., 2013. Naturalness preserved enhancement algorithm for non-uniform illumination images, *IEEE transactions on image processing*, *22*(9):3538-3548.

WANG, W., WU, X., YUAN, X. and GAO, Z., 2020. An experiment-based review of low-light image enhancement methods. *Ieee Access*, *8*:87884-87917.

WANG, Y., WAN, R., YANG, W., Lİ, H., CHAU, L.P. and KOT, A., 2022. Low-light image enhancement with normalizing flow, In *Proceedings of the AAAI Conference on Artificial Intelligence* Vol. 36, No. 3:2604-2612.

WEİ, C., WANG, W., YANG, W. and LİU, J., 2018. Deep retinex decomposition for low-light enhancement, *arXiv preprint arXiv:1808.04560*.

WEİ, X., ZHANG, X. and Lİ, Y., 2022. Tsn-ca: A two-stage network with channel attention for low-light image enhancement, In *Artificial Neural Networks and Machine Learning–ICANN 2022: 31st International Conference on Artificial Neural Networks, Bristol, UK, September 6–9, 2022, Proceedings, Part III* :286-298.

XU, K., CHEN, H., XU, C., JİN, Y. and ZHU, C., 2022. Structure-texture aware network for low-light image enhancement, *IEEE Transactions on Circuits and Systems for Video Technology*, *32*(8):4983-4996.

XU, Q., JİANG, H., SCOPİGNO, R. and SBERT, M., 2014. A novel approach for enhancing very dark image sequences, *Signal processing*, *103*:309-330.

YANG, W., WANG, S., FANG, Y., WANG, Y. and LİU, J., 2020. From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement, In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*:3063-3072.

YİNG, Z., Lİ, G., REN, Y., WANG, R. and WANG, W., 2017. A new low-light image

enhancement algorithm using camera response model, In *Proceedings of the IEEE international conference on computer vision workshops*:3015-3022.

YUANTAO, Z., MENGYANG, C., DEXİN, S. and YİNNİAN, L., 2018. Digital TDI technology based on global shutter sCMOS image sensor for low-light-level imaging, *Acta Optica Sinica*, *38*(9):144-151.

ZHAİ, Y., NEUHOFF, D.L. and PAPPAS, T.N., 2013. Local radius index-a new texture similarity feature, In *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*:1434-1438.

ZHANG, M., MOU, X. and ZHANG, L., 2011. Non-shift edge based ratio (NSER): An image quality assessment metric based on early vision features, *IEEE Signal Processing Letters*, *18*(5):315-318.

ZHANG, Y., Dİ, X., ZHANG, B. and WANG, C., 2020. Self-supervised image enhancement network: Training with low light images only, *arXiv preprint arXiv:2002.11300*.

ZHOU, F., SUN, X., DONG, J. and ZHU, X.X., 2023. SurroundNet: towards effective low-light image enhancement, *Pattern Recognition*, *141*:109602.

ZHU, M., PAN, P., CHEN, W. and YANG, Y., 2020, April. Eemefn: Low-light image enhancement via edge-enhanced multi-exposure fusion network, In *Proceedings of the AAAI Conference on Artificial Intelligence* Vol. 34, No. 07:13106-13113.