

Dikkat Mekanizmalarının Düşük Aydınlıklı Görüntü İyileştirme Üzerindeki Etkileri

Mine Onat, Serdar Çiftçi

Batman Üniversitesi Mühendislik Mimarlık Fakültesi - Bilgisayar Mühendisliği Bölümü, Batman
Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Şanlıurfa

Doi: 10.55024/buyasambid.1322474

Makale Bilgisi

Özet

Makale geçmişi:

İlk gönderim tarihi: 04.07.2023
Düzeltilme tarihi
Kabul tarihi: 11.07.2023
Yayın tarihi: 14.07.2023

Anahatar Kelimeler:

Düşük Aydınlıklı Görüntü
İyileştirme, Dikkat
Mekanizması, Derin Öğrenme.

* Mine Onat
E-mail address:
mine.onat@batman.edu.tr
Orcid:
0000-0003-4167-1487

Düşük aydınlıklı görüntü iyileştirme problemi bilgisayarlı görü alanında yaygın olarak çalışılmasına rağmen renk sapmaları sorunu tam olarak çözülebilmemiş değildir. Bu çalışmada düşük aydınlıklı görüntü iyileştirmede başarılı sonuçlar sergileyen SSIENet mimarisi üzerinde farklı dikkat mekanizmalarının kullanılmasıyla renk sapmalarının önlenmesini inceledik. Deneyler için etkili kanal, uzamsal ve sıkma uyarma, sıkma ve uyarma, kanal dikkat, koordinat dikkat ve darboğaz dikkat mekanizmalarını kullandık. Dikkat mekanizmalarının kullanılmasının düşük aydınlıklı görüntü iyileştirmede PSNR, SSIM, LRI ve NSER metrik değerlerini arttırdığını bulduk. Özellikle sıkma ve uyarma dikkat mekanizmasının düşük aydınlıklı görüntü iyileştirmede çok daha etkili olduğu görülmüştür. .

Effects Of Attention Mechanisms On Low Light Image Enhancement

Mine Onat, Serdar Çiftçi

Batman Üniversitesi Mühendislik Mimarlık Fakültesi - Bilgisayar Mühendisliği Bölümü, Batman
Harran University, Faculty of Engineer, Department of Computer Engineer, Batman, Türkiye

ARTICLE INFO

ABSTRACT

Article history:

Received: 04.07.2023
Received in revised form
Accepted: 11.07.2023
Available online: 14.07.2023

Key words:

Low Light Image Enhancement,
Attention Mechanisms, Deep
Learning.

* Mine Onat.
E-mail address:
mine.onat@batman.edu.tr
Orcid:
0000-0003-4167-1487

Although the low-light image enhancement problem is studied widely in the computer vision field, the issue of chromatic aberration has not been fully solved. In this study, we investigated preventing the aberration problem by employing different attention mechanisms on the SSIENet architecture, which performs successful results in low-light image enhancement. Our experiments used effective channel, spatial and squeeze and excitation, squeeze and excitation, channel attention, coordinate attention, and bottleneck attention mechanisms. We found that using attention mechanisms in low-light image enhancement increases the values of PSNR, SSIM, LRI, and NSER metrics. Especially the squeeze and excitation attention mechanism is much more effective in low-light image enhancement.

1. GİRİŞ

Günümüzde bilgisayarlı görü birçok alanda kullanılmaktadır. Bilgisayarlı görünün hizmet ettiği tıp, askeri, güvenlik, ticari ve benzeri birçok alanda görüntülerin netliği büyük önem arz etmektedir. Görüntü netliğini artırmayı amaçlayan bilgisayarlı görü aynı zamanda bu alanların başarısını da önemli ölçüde etkilemektedir. Bu yüzden bilgisayarlı görünün kapsamı içerisine giren konular görüntü netliğini ileri seviyelere götürme amacıyla birbirleriyle yarışmaktadırlar.

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 aldıkları sahnelerin karanlık olması gibi, uzun tutulduğunda aldıkları sahnelerin ise fazla aydınlıktan dolayı görüntü netliği istenilen yüksek dinamik aralığa ulaşamamaktadır. Pozlama süresi kısa tutularak elde edilen karanlık sahne netlikten uzaklaşmanın yanı sıra gürültü de ortaya koyar. Pozlama süresi uzun tutularak elde edilen fazla aydınlık sahne bulanıklaşırken aynı zaman da fotoğraf çekilirken sürenin uzun tutulmasıyla eldeki titremeden kaynaklı problemleri de beraberinde getirmektedir.

Fotoğraf makinelerinin sınırlı dinamik aralık problemini çözmek için çeşitli yaklaşımlar bulunmaktadır. Bunlar iki şekildedir: Çoklu pozlama ile füzyon algoritmaları ve tek girdi ile kontrast geliştirme algoritmalarıdır. Çoklu pozlama füzyonu algoritmaları aynı sahneden birden fazla girdi aldıkları için farklı detaylar elde edebilmenin avantajına sahip olmanın yanı sıra füzyon işleminin başarısızlığından çeşitli artefaktlar bırakır ve birden fazla girdi aldığından yüksek hesaplama maliyetine sahip olur (Lu vd., 2020). Aynı sahnenin birden fazla görüntüsünün elde edilmesi zor olduğundan bu çalışmada tek görüntüye odaklanılmıştır.

SSINet (Zhang vd., 2020) çalışması retineks teorisi ve evrişim sinir ağlarından oluşan bir modelle tek görüntü üzerinde geliştirme yapmıştır. Günümüzde bilgisayarlı görüde dikkat mekanizmalarının kullanımı başarılı sonuçlar üretmiştir. Bu çalışmada, SSINet (Zhang vd.,2020) mimarisine dikkat mekanizmaları eklemenin nasıl etki edeceği incelenmiştir. Ayrıca kullanılan dikkat mekanizmalarının birbirlerine göre performanslarının değerlendirilmesi yapılmıştır.

İlgili Çalışmalar

Görüntü kalitesini geliştirmeyi amaçlayan düşük aydınlıklı görüntü geliştirme çalışmaları literatürde kontrast geliştirme, pozlama düzeltme olarak da adlandırılır. Düşük aydınlıklı görüntü geliştirme algoritmaları Histogram eşitleme, Retinex teorisi, Buğu giderme ve Derin öğrenme gibi farklı yöntemlerle geliştirilir.

Histogram Eşitleme; bir görüntüdeki renklerin belli bir yere dağılmasından kaynaklı bozukluğu, renk dağılımını dengeli bir şekilde dağıtarak gideren bir görüntü işleme tekniğidir. Bilgisayarlı görü çalışmalarında temel işlem olarak kullanılabilirdiği gibi diğer çalışmalara ön işlem olarak da kullanılmaktadır.

Retineks Teorisi; görüntüyü yansıtmaya ve aydınlatmaya bileşenine ayıran bir tekniktir. Görüntüyü iki ayrı bileşene ayırarak görüntünün daha detaylı analiz edilmesine olanak sağlar. Bu özelliğinden ötürü birçok bilgisayarlı görü çalışmasında sürekli tercih edilen bir yöntemdir.

Buğu Giderme; karanlık bir görüntünün ters çevrilip karanlık bir kanala dayalı buğu çözme algoritmasının uygulanmasından sonra tekrar ters çevirme tekniğidir. Düşük aydınlıklı bir görüntü ters çevrildiğinde elde edilen görüntü sisli bir ortamda elde edilen gündüz görüntüsüne benzer olduğundan düşük aydınlıklı görüntü geliştirme çalışmalarında kullanılmaktadır.

Derin Öğrenme; makine öğrenme yöntemidir. Bir görüntüdeki özellikleri manuel olarak çıkarmak yerine otomatik bir şekilde yapar (Çalışkan, 2023). Manuel olarak elde edilemeyecek kadar başarılı özellikler öğrendiğinden bilgisayarlı görü de en çok tercih edilen yöntemdir (Çalışkan, 2023).

Histogram eşitleme kullanarak kontrast geliştirme yapan DHE (Wadud vd., 2007) çalışması görüntü histogramını yerel minimumlara göre bölümlere ayırır. Bölümleri ayrı ayrı eşitlemeden önce her bölüm için belirli gri seviye aralıkları atar. Bu bölümleri ayrıca herhangi bir baskın bölümün bulunmadığından emin olmak için bir yeniden bölümlendirme testinden geçirerek solgun efekt ve

istenmeyen yan etkiler çıkmadan kontrastı iyi bir şekilde arttırır (Wadud vd., 2007). GTV (Hao vd., 2020). çalışması tek bir görüntüdeki sınırlı bilgi nedeniyle bu sınırlı bilgileri arttırmak için giriş görüntüleri retineks yöntemiyle çoğaltıp girdi olarak kabul eder. İlk evrede Retineks teorisinin yansıtma bileşenini almayıp, ikinci evrede yansıtma ve aydınlatma bileşenlerinin ikisini de alır. Düşük aydınlıklı giriş görüntüsündeki gürültüyü dikkate alıp yansıtma ekleyerek $S=I \circ (R+N)$ hem geliştirme kaliteli hem de optimizasyon oranının hızlı yakınsamasını sağlamıştır (Hao vd., 2020). Girdi görüntüyü HSV uzayına çeviren ADM (Liv vd., 2018) çalışması V kanalındaki gürültüyü de hesaba katacak şekilde programlanmıştır. Retineks ayrıştırmasıyla bu kanalda işlemler gerçekleştirilmektedir. Birleştirmenin ardından tekrar RGB uzayına çevirerek retineksin geliştirilmiş versiyonunu kullanmaktadır (Liv vd., 2018). Görüntüyü yansıtma ve aydınlatma bileşenlerine ayıran LIME çalışması tahmin haritası olarak sadece aydınlatma haritasının tahminini yapıp retineks teorisine düşük aydınlıklı görüntü geliştirmede farklı bir bakış açısı sunmuştur (Guo vd., 2016). Li ve arkadaşlarının yaptığı çalışma düşük aydınlıklı görüntülerde gürültü kaçınılmaz olduğundan görüntüyü gürültüden kurtarmak için sisli görüntüye çevirir. Ardından tekrar geliştirilmiş düşük aydınlıklı görüntüye çevirme işlemi yaparak ilk gürültü giderme ardından kontrast geliştirme yapar (Liv d., 2015). Tanaka ve arkadaşlarının gradyana dayalı geliştirme çalışması gradyanlar koyu bölgelerde küçük olmaya eğilimli olduklarından YCbCr uzayındaki girdilerin Y (luminans) kanalında gradyanları geliştirerek düşük aydınlıklı görüntüleri iyileştirmiştir (Tanaka vd., 2019). Tek bir pozlama oranı belirleyerek her piksel için iyi pozlanmış oran sağlanamadığı düşüncesinden hareket eden CRM çalışması uygun kamera yanıt modelini bulup pozlama oranı haritasına karar vererek düşük aydınlıklı görüntü geliştirmesi yapmıştır (Ying vd., 2017).

Şimdiye kadar düşük aydınlıklı görüntülerde iyileştirme olarak bahsedilen metodlar manuel olarak görüntü işleme ve matematik teknikleriyle literatüre eklenmiş çalışmalardır. Ancak biz insanların manuel olarak ortaya çıkaramayacağımız ve gözlerimizle göremeyeceğimiz kadar büyük özellikleri otomatik yeteneğiyle ortaya çıkarabilen ayrıca son zamanlarda her ne kadar birçok alanda başarı gösterse de hala gelişimi için uzun bir yolu olan derin öğrenme yöntemleriyle de yapılmış birçok düşük aydınlıklı görüntü geliştirme çalışmaları literatüre kazandırılmıştır. ABSGN (Chen vd., 2022) çalışması girdiyi Ayrık Dalgacık Dönüşümünden (Discrete Wavelet Transform) çok çözünürlüklü hale getirir. 3 girdi içinde genişletilmiş evrişimin (dilated convolution) ve kanal mekanizmasının bulunduğu Çok-Seviyeli Rehberli Yoğun Bloktan (Multi-level Guided Dense Block), bir girdi içerisinde mekânsal dikkat modülünde bulunduğu Geleneksel Mekansal Dikkat (Global Spatial Attention) modülden geçirir. Bu modüllerden çıkan çıktıları birleştirme yaparak güçlü bir derin öğrenme mimarisi sunmuştur (Chen vd., 2022). SCL-LLE (Liang vd., 2022) çalışması eğitim verisine bağlılığı kaldırarak yapıcı öğrenme modülüyle negatif (az pozlanmış, çok pozlanmış) girdi ve pozitif (normal pozlanmış) girdiyi özellik açısından geçirmiştir ve özellik çıkarımı yapmıştır. Düşük aydınlıklı girdi görüntüsünü görüntü iyileştirme açısından geçirip iyileştirilerek bu çıktıyı anlamsal bölütleme (semantic segmentation) açısından geçirmiştir. Ardından bu 3 ağın sonuçları arasında kayıp fonksiyonu kullanmıştır (Liang vd., 2022). LLFlow basit olasılıklı dağılım dönüşümüyle farklı haritalar oluşturup

bunlar arasında şartlı öğrenme yaparken aynı zamanda aynı girdiye farklı ağda uygulamış olduğu evrişim ve kalıntıların çıktılarını birleştirerek yüksek aydınlıklı görüntü üretmiştir (Wang vd., 2022). STANet (Xu vd., 2022) karşı haritalama (Counter Map) ile girdiyi kodlayıcı-kod çözücü ve mekânsal dikkatten geçirdiği Yapısal haritalar (Structure Maps) ve kodlayıcı- kod çözücü ve kanal dikkatten geçirdiği Doku haritalarına (Texture Maps) ayırmıştır. Bu mimarilerden geçirdiği çıktıları evrişimlerle birleştirip yüksek aydınlıklı görüntüyü elde etmiştir (Xu vd., 2022). DRBN (Yang vd., 2020) özyinelemeli kodlayıcı-kod çözücülerle her seferinde kod çözücü katmanlarından şu ana kadarki çalışmaların farklı ayrıştırma yöntemiyle elde ettiklerini derin öğrenmeyi yinelemeli kullanarak elde edecek şekilde tasarlamıştır. Yani ayrıştırma işlemini daha kaliteli girdiler üreterek çıktı kalitesini de arttıran bir çalışma sunmuştur (Yang vd., 2020).


CCM (Kim vd., 2022) düşük aydınlıklı girdiyi YCbCr uzayına çevirip Y (luminans) kanalında evrişim sonrası içinde kanal dikkat bulunduğu kalıntı bloklardan geçirmiştir. İlk Y (luminans) kanalından çıkan çıktı ile birleştirerek gauss filtresinden geçirip Çekirdek Yoğunluk Tahmini (Kernel Density Estimation) denilen farklı bir histogramdan geçirmiştir (Kim vd., 2022). LEUGAN Gan modelinin üretici kısmında kenar geliştirme, kodlayıcı ve dikkat bulundurarak yüksek aydınlıklı görüntü elde etmiştir (Qu vd., 2020). SurroundNet ilk olarak gürültü kaldırıp sığ bir özellik çıkarımının ardından Uyarlanabilir Retineks (Adaptive Retinex) ve Etkili Kanal Dikkat ile beraber kullanımıyla düşük aydınlıklı görüntü geliştirmiştir (Zhou vd., 2023). LLNet gürültü giderme ve kontrast geliştirmek için bir derin kodlayıcı-kod çözücü sunmuştur (Lore vd., 2017). Zero-DCE referans veriye ihtiyaç duymadan evrişim bloğunun ardından en iyi eğriyi tahmin eden bir sistem geliştirmiştir (Guo vd., 2020). DLN Evrişimden geçirilen girdiyi düşük aydınlıklı görüntü ardından kodlayıcı-kod çözücü ve sıkma ve uyarma modüllerinden geçirip gelişmiş çıktı elde edecek şekilde programlanmıştır (Wang vd., 2020). Ren ve arkadaşlarının çalışması Kodlayıcı-kod çözücü ve Özyinelemeli Yapay Sinir Ağı (RNN) olmak üzere iki güçlü derin öğrenme mimarilerini kullanarak düşük aydınlıklı görüntü geliştirme yapmaya çalışmıştır (Ren vd., 2019). TBEFN (Lu vd., 2020) girdi görüntüsünden -1 pozlama değeri ve -2 pozlama değerinde 2 girdi üretilip -2 pozlama değerindeki girdi daha karanlık olduğundan gürültü oluşma ihtimalinin yüksekliğinden ötürü ön işleme gerçekleştirmiştir. Ardından 2 girdi de U-Net mimarilerinden geçirilmiştir. Dikkat modülünden de geçirildikten sonra birleştirme işlemini yapmıştır. Sonunda da evrişimle düşük aydınlıklı görüntüden gelişmiş çıktı üreten çalışma gerçekleştirmiştir (Lu vd., 2020). Multi Exposure Fusion (MEF) ve Single Image Contrast Enhancement (SICE) konularını birleştiren CNN geliştirici çalışma her bir kanala ağırlıklı En Küçük Kareler (WLS) yöntemi uygulayarak girdi görüntüleri ayırtmıştır. Yansıtma girdisini evrişimlerden, aydınlatma girdisini U-Net mimarisinden geçirip çıktıları birleştirmiştir. Evrişim işlemlerinden sonra gelişmiş görüntüyü üretmiştir (Cai vd., 2018). MSR-NET (Shen vd., 2017) çok ölçekli logaritmik dönüşümle bir dizi girdi üretmiştir. Ardından atlamalı bağlantılar eşliğinde evrişim bloklarıyla yüksek aydınlıklı görüntü oluşturmuştur (Shen vd., 2017). TSN-CA (Wei vd., 2018) girdiyi HSV uzayına çevirir. V kanalı gürültü içermeksizin birçok yüksek

frekanslı bilgi içerdiğinden bu kanal içerisinde kanal dikkat mekanizmasının bulunduğu bir U-Net ile geliştirme yapmıştır (Wei vd., 2018). Lv ve arkadaşlarının çalışması (Lv vd., 2021) girdiyi içerisinde dikkat mekanizması olan U-Net'in ardından daha da geliştirme adına genişletilmiş evrişimden geçirmiştir. Ardından renk düzeltmek için evrişim ve U-Net tekrar uygulanır. Sonunda detay geliştirmek için tekrar genişletilmiş evrişimle çıktı görüntü elde etmiştir (Lv vd., 2021). EEMEFN (Zhu vd., 2020) girdi görüntüyü pozlama füzyonundan ilham alarak iki farklı pozlama oranı ile çarpıp iki girdi oluşturmuştur. Ardından her ikisini de ayrı dallarda U-Net mimarisinden geçirip her katmanda birinden ortalama diğerinden maksimum olarak füzyon blokları oluşturmuştur. U-Net çıkışında bir evrişimle birleştirme yapmış ve bu çıktıyı girdi olarak düşünüp kenar belirleme algoritması olan Canny ile kenar geliştirdikten sonra bu çıktıyı tekrar başka bir U-Net mimarisine girdi olarak verip final gelişmiş çıktı üretmiştir (Zhu vd., 2020). Enlightengan denetimsiz öğrenme ile gan modelinin üretici kısmında dikkat mekanizmalı U-Net besleyen, sınıflandırıcı kısmındaysa geleneksel ve lokal olmak üzere iki sınıflandırıcı içeren geliştirme yapmıştır (Jiang vd., 2021). LLCNN bir koldan 3x3 evrişim diğer koldan 1x1 evrişimden geçirerek birleştirip yüksek aydınlıklı çıktı görüntü üretmiştir (Tao vd., 2017).

2. YÖNTEM

SSIENet

Bu çalışmada, düşük aydınlıklı görüntü iyileştirme algoritması olan Zhang ve arkadaşlarının SSIENet algoritması iskelet olarak kullanılmıştır. SSIENet düşük aydınlıklı girdi görüntüyü Retineks teorisiyle 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. Önceki olasılıklar olan yansıma ve aydınlatma maksimum arka olasılığı, yansıtma ve aydınlatmayı bulmak için eklenmiştir. Aydınlatma ve yansıma kaybının yanı sıra yeniden yapılandırma kaybı da hesaplanmıştır. 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 1'de gösterilmiştir.

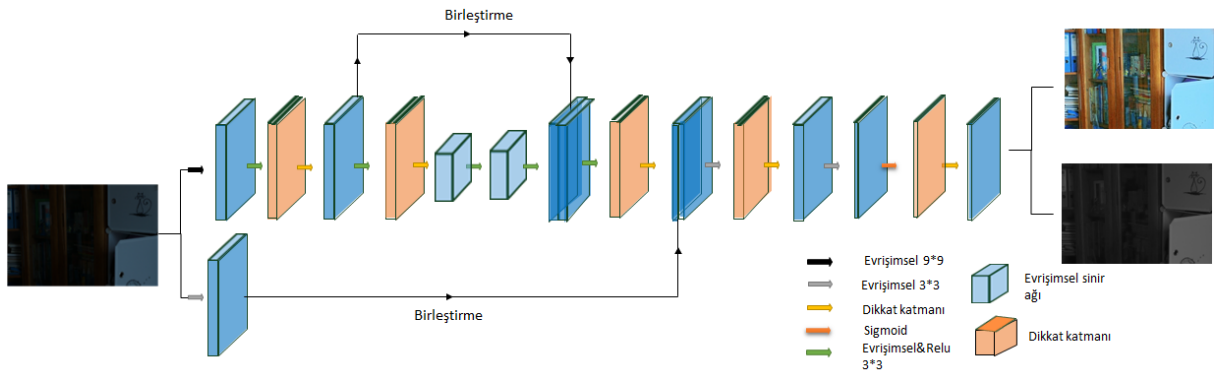


Şekil 1. SSIENet'in Mimari Yapısı (Zhang ve arkadaşları, 2020)

Dikkat Mekanizmaları

Doğal dil işlemeyle başlayıp ardından bilgisayarlı görüde yayılan dikkat mekanizması dikkat olayını taklit etmeyi amaçlayan tekniktir. Dikkat mekanizması girdi verilerinin önemli kısımlarına yoğunlaşırken, önemsiz kısımlarını göz ardı eder. İlk olarak cümle içerisindeki her bir kelimeyi vektöre dönüştürür. Daha sonra bu kelimelerden hangisinin daha etkili olup ya da etkisiz olduğunu bulmak adına doğrusal kombinasyon olarak seçilir. Bu seçim işlemini olasılığı yüksek olanı önemli diye nitelendirerek yapar. Dikkat mekanizmasının çalışma sistemi metinde nasıl ilerliyorsa görüntüde de aynı sistem kelime yerine hangi pikselin baskın olup aktarılması şeklinde ilerler.

SSIENet kontrast geliştirme çalışmasından yola çıkarak ve dikkat mekanizmalarının bilgisayarlı görüdeki başarısı göz önüne alınarak SSIENet'e dikkat mekanizması eklenerek nasıl etkileneceği incelenmiştir. Bu çalışmada önerilen yöntemin sıklıkla kullanılan dikkat mekanizmalarıyla etkisi ölçülmüştür. Oluşturulan mimari yapısında kullanılan dikkat mekanizmalarını farklı katmanların farklı yerlerine eklenerek denenmiştir. En iyi sonucun alındığı katmanların bulunduğu mimari yapısı Şekil 2'de gösterilmiştir.




Şekil 2. SSIENet Çalışmasından (Zhang ve arkadaşları, 2020) Uyarlanmış Mimari.

Sıkma ve Uyarma Dikkat Ağı

Sıkma ve Uyarma dikkat mekanizması (Hu vd., 2018), geleneksel bilgede modele yardım eder ve son sınıflandırma kararına katkı sağlayarak bilgilendirici kanallarla modelin duyarlılığını artırır. Bu ağ, herhangi bir dönüşüm için $F_{tr} : X \rightarrow U$, $X \in \mathbb{R}^{H \times W \times C}$, $U \in \mathbb{R}^{H \times W \times C}$ oluşturulabilen bir hesaplama birimidir. Basit olması için, takip eden notasyonda F_{tr} bir evrişim işlemine alınır. $V = [v_1, v_2, \dots, v_c]$ v_c 'nin c . filtresinin parametrelerini ifade ettiği öğrenilen filtre çekirdeği setini gösteriyor. Ardından F_{tr} çıktısı $U = [u_1, u_2, \dots, u_c]$ şeklinde yazılabilmektedir, burada

$$u_c = v_c * X = \sum_{s=1}^{c'} v_c^s * X^s \quad (1)$$

Burada $*$ evrişimi göstermektedir. $V_c = [v_c^1, v_c^2, \dots, v_c^{c'}]$ ve $X = [x^1, x^2, \dots, x^{c'}]$, v_c^s iki boyutlu çekirdekken ve bu yüzden x 'in karşılık gelen kanalı üzerinde hareket eden v_c 'nin tek kanalını temsil eder. 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 faydalanabilmesi ve daha az kullanışlı olanları bastırabilmesi amacıyla bilgilendirici özellikler için ağı duyarlılığını arttırabilmektedir. Sıkma ve Uyarma bloğu Şekil 3'de gösterilmiştir.



Şekil 3. Sıkma ve Uyarma Ağı (Hu ve arkadaşları, 2018)

Kanal Dikkat Ağı

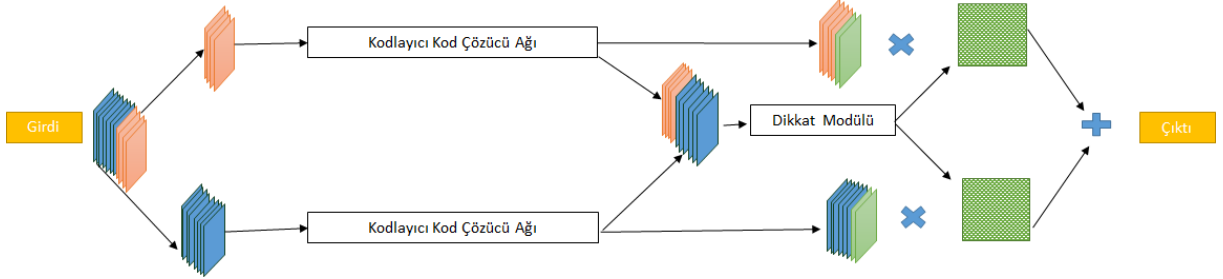
Kanal dikkat mekanizması tek kanallar üzerinde yumuşak dikkat kullanan bir derin öğrenme ağıdır. $s \in \{1, \dots, S\}$, her bir kanal için verilen özellik haritaları X_s , üretilen final tahmin :

$$Y = \sum_{s=1}^S W_s \cdot \text{Softmax}(X_s) \quad (2)$$

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

$$W = \text{Softmax}(\Phi(X_1 \oplus X_2 \oplus \dots \oplus X_S)) \quad (3)$$

Tüm ağıın ortak eğitimi boyunca, dikkat ağı görüntü bağımlı şekilde her bir kanalın ağırlık katkılarını öğrenir. Hem dikkat hem birleştirme yaklaşık olarak toplam aynı parametre sayısına sahiptirler, çünkü ikisi de paylaşılmayan parametrelerle çoklu kanala sahiptirler. Kanal dikkat ağı Şekil 4’te gösterilmiştir.



Şekil 4. Kanal Dikkat Mekanizması(Bastidas ve arkadaşları, 2019)

Etkili Kanal Dikkat Ağı

Sıkma ve Uyarma ağıının içinde kanal dikkat modülü detaylandırılarak kanallar arası etkileşim ve boyutsal küçültmenin etkileri de göz önüne alınarak etkili bir kanal dikkat mekanizması elde edilmiştir. İlk olarak Sıkma ve uyarma ağıının içinde kanal dikkati incelediğimizde $X \in \mathbb{R}^{W \times H \times C}$ bir evrişim bloğunun çıktısıdır, burada W genişlik, H yükseklik ve C kanal boyutudur. Sıkma ve Uyarma bloğundaki kanalların ağırlıkları şöyle hesaplanır:

$$\omega = \sigma(f_{\{W_1, W_2\}}(g(X))) \quad (4)$$

Burada $g(x) = \frac{1}{WH} \sum_{i=1, j=1}^{W, H} X_{ij}$ kanal bazlı Küresel Ortalama Havuzlama (GAP) ve σ sigmoid fonksiyonudur. $y = g(x)$, $f_{\{W_1, W_2\}}$ formu;

$$f_{\{W_1, W_2\}}(y) = W_2 \text{ReLU}(W_1 y) \quad (5)$$

Burada RELU (Rectified Linear Unit) aktivasyon fonksiyonunu göstermektedir. Yüksek model karmaşıklığından kaçınmak için W_1 ve W_2 'nin boyutları $C \times \left(\frac{C}{r}\right)$ ve $\left(\frac{C}{r}\right) \times C$ şeklinde ayarlanır. $f_{\{W_1, W_2\}}$ 'in kanal dikkat bloğunun tüm parametrelerini içermektedir. Yukarıdaki eşitlikte boyut azaltma model karmaşıklığını azaltabilirken, kanal ve kanalın ağırlığı arasındaki doğrudan karşılığını tahrip eder. Bu yüzden kanal boyut azaltma olmaksızın Etkili kanal dikkat modülü geliştirilmiştir.

Boyut azaltma olmaksızın $y \in \mathbb{R}^C$ toplu özellik göz önüne alındığında kanal dikkat öğrenme;

$$\omega = \sigma(Wy) \quad (6)$$

Burada W $C \times C$ parametre matrisidir.

$$W=\{W_{var2} = [W^{1,1} \dots 0 \vdots \vdots \vdots 0 \dots W^{C,C}], W_{var3} = [W^{1,1} \dots W^{1,C} \vdots \vdots \vdots W^{1,C} \dots W^{C,C}]\} \quad (7)$$

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

$$W_G=[W_G^1 \dots 0 \vdots \vdots \vdots 0 \dots W_G^C] \quad (8)$$

Burada G grupların her biri $\frac{C}{G}$ kanallar içeren kanala ayrılıyor ve yerelde çapraz kanal etkileşimini ele geçiren bağımsız bir şekilde her bir gruptaki kanal dikkati öğreniyor. Buna göre, $\frac{C^2}{G}$ 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 ;

$$\begin{bmatrix} w^{1,1} & \dots & w^{1,k} & 0 & 0 & \dots & \dots & 0 & 0 & w^{2,2} & \dots & w^{2,k+1} & 0 & \dots & \dots & 0 & \vdots & 0 & \vdots \\ \dots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & 0 & 0 & \dots & w^{c,c-k+1} & \dots & w^{c,c} & \dots & \dots & \dots & \vdots & \vdots & \vdots \end{bmatrix} \quad (9)$$

Eşitlik (9)'daki W_k eşitlik (8)'dekinden genellikle daha az olan kxC parametre içerir. Ek olarak eşitlik (9), eşitlik(8)'deki farklı gruplar arasındaki tam bağımsızlıktan kaçınır. Eşitlik (8)'deki metod eşitlik (9)'daki SE-GC'den yüksek performans gösterir. Eşitlik (9)'a gelince y_i 'nin ağırlığı y_i ve k komşuluğu ile arasındaki sadece etkileşim düşünülerek hesaplanılır, örneğin,

$$W_i = \sigma(\sum_{j=1}^k \omega_i^j y_i^j), y_i^j \in \Omega_i^k \quad (10)$$

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

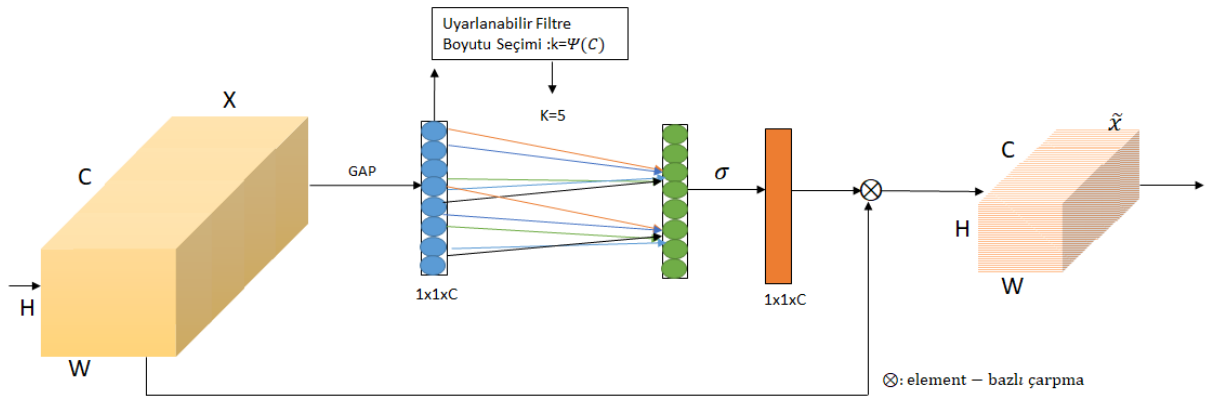
Daha etkili bir yol aynı öğrenilen parametreleri tüm kanallara paylaşmaktır,

$$W_i = \sigma(\sum_{j=1}^k w^j y_i^j), y_i^j \in \Omega_i^k \quad (11)$$

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

$$W = \sigma(C1D_k(y)) \quad (12)$$

Burada C1D 1D evrişimi gösteriyor. Eşitlik (12)'deki metod sadece k parametrelerini içeren Etkili Kanal Dikkat modül olarak adlandırılır. Şekil 5'te Etkili kanal dikkat'in mimarisi verilmiştir.



Şekil 5. Etkili Kanal Dikkat Mekanizması(Wang ve arkadaşları, 2020)

Darboğaz Dikkat Ağı

Verilen giriş özellik haritası $F \in \mathbb{R}^{C \times H \times W}$ için, Ağ $M(F) \in \mathbb{R}^{C \times H \times W}$ 3D dikkat haritası çıkarmaktadır. Onarılmış özellik haritası F' şöyle hesaplanmaktadır:

$$F' = F + F \otimes M(F) \quad (13)$$

Burada \otimes element bazlı çarpmayı gösterir. Gradyan akış olanağı için dikkat mekanizmasıyla birlikte artık öğrenme şeması benimsenmektedir. Etkili güçlü modül tasarımı için, $M_c(F) \in \mathbb{R}^C$ ilk kanal dikkat ve $M_s(F) \in \mathbb{R}^{H \times W}$ uzamsal dikkat iki branşa ayrıldıktan sonra dikkat haritası $M(F)$ eşitlik (14)'deki gibi hesaplanmaktadır:

$$M(F) = \sigma (M_c(F) + M_s(F)) \quad (14)$$

Burada σ sigmoid fonksiyonudur. Eklemeden önce iki branş çıktıları $\mathbb{R}^{C \times H \times W}$ için yeniden boyutlandırılıyor.

Kanal dikkat branşı: Her bir kanal özel özellik yanıtı içerdiğinden, kanal branşında kanallar arası ilişki kullanılıyor. Her bir kanaldaki özellik haritasını toplamak için, özellik haritası F üzerinde geleneksel ortalama havuzlama alınır ve $F_c \in \mathbb{R}^{C \times 1 \times 1}$ kanal vektörü üretilir. Bu vektör her bir kanalda evrensel bilgi kodlamaktadır. 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 $\mathbb{R}^{C/r \times 1 \times 1}$ 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 hesaplanır:

$$\begin{aligned} M_c(F) &= BN(MLP(AvgPool(F))) \\ &= BN(W_1(W_0 AvgPool(F) + b_0) + b_1) \end{aligned} \quad (15)$$

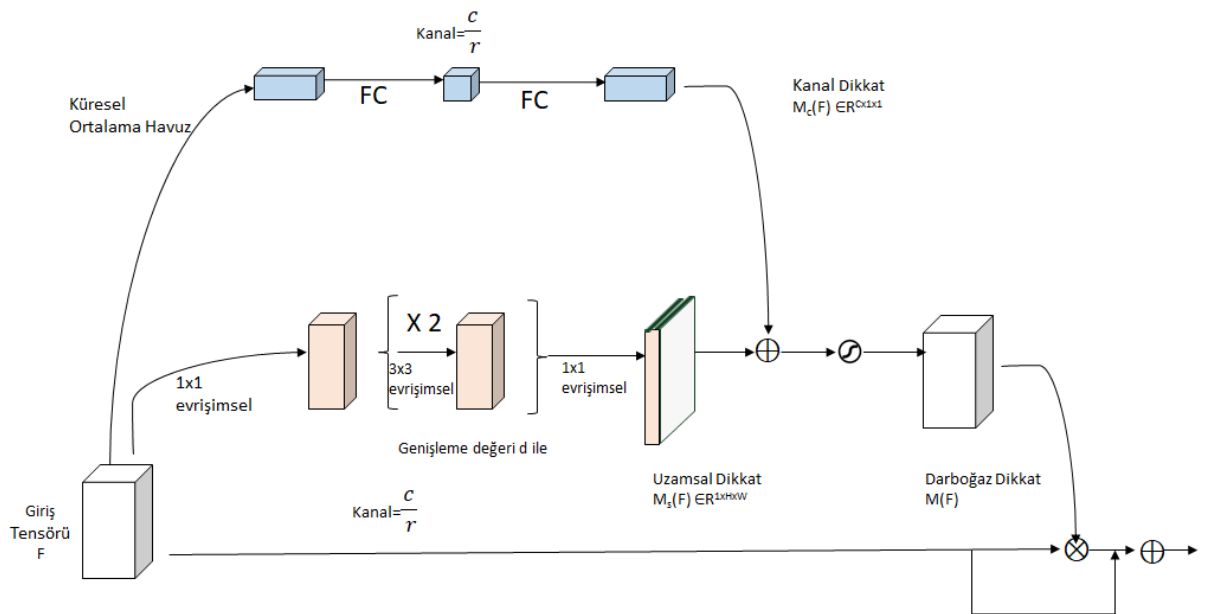
Burada $W_0 \in \mathbb{R}^{C/r \times C}$, $b_0 \in \mathbb{R}^{C/r}$, $W_1 \in \mathbb{R}^{C \times C/r}$, $b_1 \in \mathbb{R}^C$ dir.

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 odaklanması 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. $F \in R^{C \times H \times W}$ özellik entegre için 1×1 evrişim kullanarak $R^{C/R \times h \times w}$ 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 3×3 'lük genişletilmiş evrişim uygulanır. Son olarak, 1×1 evrişim kullanarak $R^{1 \times H \times W}$ uzamsal dikkat haritası için özellikler tekrar azaltılır. Ölçeği ayarlamak için, uzamsal branşın sonunda yığın normalizasyon (batch normalization) katmanı uygulanır. Kısacası, uzamsal dikkat şöyle hesaplanır:

$$M_s(F) = \text{BN}(f_3^{1 \times 1}(f_2^{3 \times 3}(f_1^{3 \times 3}(f_0^{1 \times 1})))) \quad (16)$$

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

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 $R^{C \times H \times W}$ 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. Darboğaz dikkat mekanizmasının yapısı Şekil 6'da verilmiştir.



Şekil 6. Darboğaz Dikkat Mekanizması (Park ve arkadaşları, 2018)

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 (17)'deki gibi formülize ediliyor. 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:

$$Z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (17)$$

w genişliğindeki c. kanalın çıktısı şöyle yazılır,

$$Z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (18)$$

(17) ve (18) 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(17) ve eşitlik(18) önce birleştirilir ve sonra paylaşılan 1x1 evrişim dönüşüm fonksiyonu F1 onlara gönderilir,

$$F = \delta(F_1([z^h, z^w])) \quad (19)$$

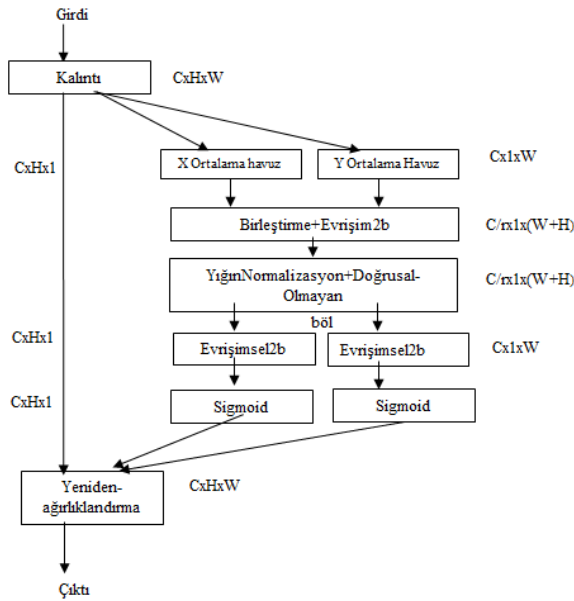
Eşitlik 19'da [.,.] uzamsal boyutla beraber birleştirme işlemidir, δ doğrusal olmayan aktivasyon fonksiyonu, ve $f \in \mathbb{R}^{C/(rx(H+W))}$ hem dikey hem yatay yönde uzamsal bilgiyi kodlayan orta seviye özellik haritasıdır. Burada r azaltma oranıdır, $f^h \in \mathbb{R}^{C/(rxh)}$ ve $f^w \in \mathbb{R}^{C/(rxw)}$ iki tensöre ayrılır. Diğer iki 1x1 evrişim dönüşümleri F_h ve F_w X girişi için aynı kanal sayısı ile f^h ve f^w ayırmada kullanılır,

$$g^h = \sigma(F_h(f^h)) \quad (20)$$

$$g^w = \sigma(F_w(f^w)) \quad (21)$$

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

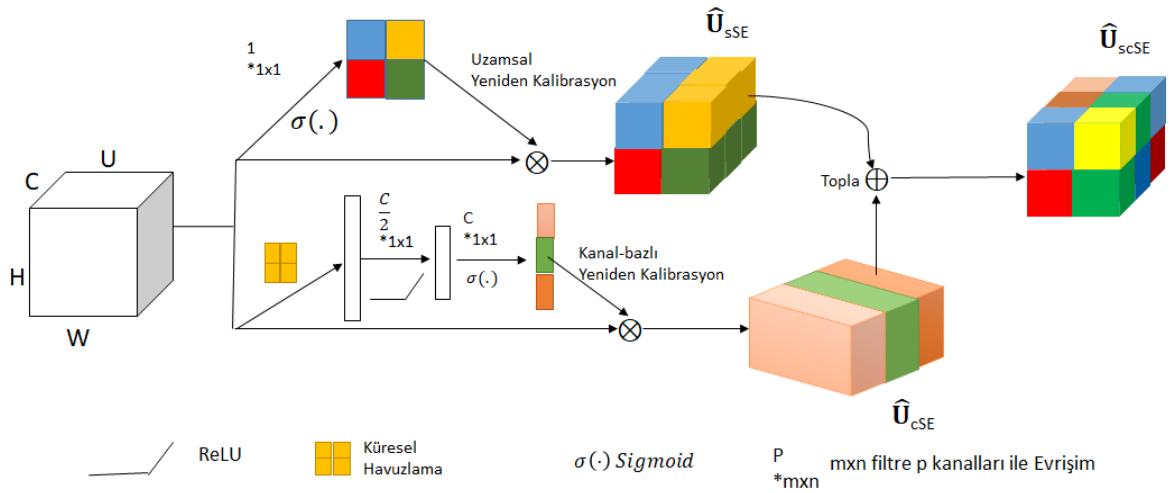
$$y_c(i,j) = X_c(i,j) \times g_c^h(i) \times g_c^w(j) \quad (22)$$



Şekil 7. Koordinat Dikkat Mekanizması(Hou ve arkadaşları, 2021)

Uzamsal ve Kanal Sıkma ve Uyarma Dikkat Ağı

Uzamsal ve Kanal Sıkma ve Uyarma ağı, eş zamanlı olarak kanal bazlı ve uzamsal U girişini yeniden kalibre eder. Kanal ve uzamsal uyarmanın eleman bazlı eklemesiyle $\hat{U}_{scSE} = \hat{U}_{cSE} + \hat{U}_{sSE}$, 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 8. Uzamsal ve Kanal Sıkma ve Uyarma Dikkat Mekanizması(Roy ve arkadaşları, 2018)

3. BULGULAR

Önerilen model düşük aydınlıklı görüntü geliştirme veri seti olan LOL (Wei vd., 2018) veri seti üzerinde eğitilmiştir. Veri seti içindeki görüntüler 600x400 boyutunda olup, toplam 500 adet görüntüden oluşmaktadır. 485 görüntü eğitim, 15 adet görüntü test için kullanılmıştır. Bu çalışma Google Colab ortamında derin öğrenme için kullanılan Tensorflow kütüphanesi kullanılarak

gerçekleştirilmiştir. Eğitim için Adam optimize edici kullanılmıştır. Bu çalışmanın performans üstünlüğünü sayısal verilerle ispatlamak için PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index Measure) metrikleri kullanılmıştır. Bu çalışmada kullanılmış olan farklı dikkat mekanizmalarının birbirlerine göre dokusal ve kenar performansları sayısal verilerle sunulmuştur. Dokusal sayısal performans kıyaslaması için LRI (Local Radius Index), kenar sayısal performans kıyaslaması için NSER (Non-Shift Edge Based Ratio) metrikleri kullanılmıştır.

Tablo 1’de de gösterildiği gibi PSNR, SSIM, LRI ve NSER sonuçları verilmiş olup, farklı dikkat mekanizmalarıyla başarılı sonuçlar elde edilmiştir. Kullanılan PSNR, SSIM, LRI ve NSER metriklerinin sayısal değerleri arttıkça başarı sonuçları da artan metriklerdirler. Zhang ve arkadaşlarının yapmış oldukları SSIENet çalışmasını eğittiğimizde 19.1574 PSNR değerine ulaşılmıştır. Dikkat mekanizmalarının detaylı özellik çıkarmanın yanı sıra renk sapmalarını önlemesi ve yapaylıktan kurtaran başarılarından yola çıkarak eklenmiş olan altı çeşit dikkat mekanizmalarıyla ilham alınan SSIENet çalışmasından daha iyi sayısal değerler elde edilmiştir. Koordinat dikkat ağında 19.0643 PSNR, darboğaz dikkat mekanizmasında 19.0952 PSNR, kanal dikkat ağında 19.5317 PSNR, uzamsal ve kanal sıkma ve uyarma dikkat ağında 19.6083 PSNR, etkili kanal dikkat ağında 20.0530 PSNR, sıkma ve uyarma dikkat ağında 20.5135 PSNR değeri elde edilmiştir. SSIENet çalışmasının SSIM değerinde 0.7108’e ulaşırken, darboğaz dikkat ile 0.7328, koordinat dikkat ile 0.7420, etkili kanal dikkat ile 0.7467, uzamsal ve kanal sıkma ve uyarma dikkat ile 0.7554, kanal dikkat ile 0.7573, sıkma ve uyarma dikkat ağı ile de 0.7657 olan en büyük SSIM değeri elde edilmiştir.

Tablo 1. Farklı Dikkat Mekanizmalarının ve SSIENet Görüntülerin PSNR, SSIM, LRI ve NSER Sonuçları

Metodlar	PSNR	SSIM	LRI	NSER
SSIENet	19.1574	0.7108	0.8237	0.9069
SSIENet+Koordinat Dikkat	19.0643	0.7420	0.8137	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 Sıkma ve Uyarma	19.6083	0.7554	0.8179	0.9143
SSIENet+Etkili Kanal Dikkat	20.0530	0.7467	0.8228	0.9035
SSIENet+Sıkma ve Uyarma Dikkat	20.5135	0.7657	0.8237	0.9100

Şekil 9’da 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 Ground Truth çıktı görüntüleri verilmiştir. İlk sütunlara bakıldığında hem duvardaki hem de kapıdaki gürültüleri en iyi temizleyen 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 Uzamsal ve Kanal Sıkma ve Uyarma dikkat mekanizması sağlamıştır. Dijital saatin kenarına bakılarak görsel sonuçta en iyi başarıyı sağladığı gibi sayısal metrik olan NSER ile de 0.9143 sonucuyla en yüksek değere ulaşarak ispatlanmıştır. İkinci sütundaki yer yüzeyinin belirginliğinin değerlendirilmesinde Sıkma ve Uyarma dikkat mekanizmasının diğer dikkat mekanizmalarına göre daha iyi dokuya sahip olduğu gözlemlenmesinin yanı sıra diğer dikkat mekanizmalarına göre daha iyi dokusal başarıya sahip olduğu LRI metriğiyle kanıtlanmıştır.



Şekil 9. Yukarıdan Aşağıya Doğru Sırasıyla Düşük Aydınlıklı Giriş, SSIENet, Sıkma ve Uyarma, Etkili Kanal, Uzamsal ve Kanal Sıkma ve Uyarma, Kanal, Darboğaz ve Koordinat ve Groundtruth Sonuçları

4. TARTIŞMA

Bu makalede altı farklı dikkat mekanizmasının düşük aydınlıklı görüntü geliştirme üzerindeki etkileri gözlenmiştir. Şekil 9'da birbirlerine göre durumları gözlemlenebilir. Dikkat mekanizmalarının doğal dil işlemedeki olağanüstü başarısından sonra, bilgisayarlı görü çalışmalarında da geldiği noktadan ilham alınarak düşük aydınlıklı görüntü geliştirme çalışmalarında da bu başarıya ulaşabileceği kanaatiyle en çok kullanılan dikkat mekanizmalarının seçimiyle hem düşük aydınlıklı görüntü geliştirmeyi sağlayıp hem de farklı dikkat mekanizmalarının birbirlerine göre performansları gözlenmiştir. Sıkma ve uyarma dikkat ağını bilgisayarlı görü de en çok kullanılan olarak seçilip ve en iyi performansı da sıkma ve uyarma dikkat mekanizmasında 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 artırılıp sıkma ve uyardaki boyut azaltmanın görüntülerde oluşturduğu tahripten ötürü boyut azaltma olmaksızın çalışmasını sürdüren Etkili kanal dikkat mekanizması bu yöntemleri sayesinde 2. en iyi başarıya ulaşmıştır. 3. 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 başarıyı 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 başarılı olan Kanal dikkat mekanizması, bu çalışmada da önemli bir başarı yakalamıştır. Kullanılan dikkat mekanizmalarından Koordinat dikkat mekanizması yatay ve dikey koordinatlarını kodlayıp iki havuz filtre kapsamı kullanarak en düşük performansı göstermektedir. Koordinat dikkat mekanizması mobil net çalışmalarındaki başarısından ötürü bu çalışmada da performansı değerlendirilmiştir. Ancak istenilen başarıyı Koordinat ve Darboğaz dikkat mekanizmalarında yakalanamasa da ilham alınan çalışmanın PSNR değeriyle aralarında çok küçük bir başarı farkı gözlenmiştir. PSNR değerine göre darboğaz ve koordinat dikkat mekanizmalarını ilham alınan SSIENet'e göre daha düşük elde edilmiş olmasına rağmen, SSIM değerine göre kullanılan tüm dikkat mekanizmalarında SSIENet'e göre yüksek performans elde edilmiştir. Ayrıca NSER metriğiyle dikkat mekanizmalarından en iyi kenar başarımını Darboğaz dikkat mekanizması elde ederken, LRI metriğiyle de en iyi doku başarımını Sıkma ve Uyarma dikkat mekanizmasının elde ettiği gözlemlenmiştir.

5. SONUÇ

Bu çalışmada düşük aydınlıklı görüntü geliştirmenin dikkat mekanizmalarının eklenmesiyle girdi görüntülerin iyileşerek daha iyi sonuçlara ulaşılmıştır. Altı farklı dikkat mekanizması kullanarak, Zhang ve arkadaşlarının yapmış oldukları çalışmaları iskelet alınıp dört tane dikkat mekanizmasıyla çok daha iyi sonuçlar elde ederken, iki dikkat mekanizmasıyla çok az bir sayısal farkla daha düşük

sonuçlar elde edilmiştir. PSNR değerine göre iki dikkat mekanizmasıyla SSINet'e göre daha düşük sayısal değer elde edilmiş olursa da SSIM değerine göre kullanılan tüm dikkat mekanizmalarıyla daha yüksek sayısal değerler elde edilmiştir. Bulunan sayısal değerler elde edilene kadar farklı katmanlar arasına dikkat mekanizmaları eklenerek eğitim ve testler yapılmıştır.

Gelecek çalışmalarda dikkat mekanizması ve retineks yönteminin birleşimiyle daha özgün bir çalışma yapılması düşünülmektedir.

6. KAYNAKÇA

- Abdullah-Al-Wadud, M., Kabir, M. H., Dewan, M. A. A., & Chae, O. (2007). A dynamic histogram equalization for image contrast enhancement. *IEEE transactions on consumer electronics*, 53(2), 593-600.
- Bastidas, A. A., & Tang, H. (2019). Channel attention networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 0-0).
- Cai, J., Gu, S., & Zhang, L. (2018). Learning a deep single image contrast enhancer from multi-exposure images. *IEEE Transactions on Image Processing*, 27(4), 2049-2062.
- Chen, Z., Liang, Y., & Du, M. (2022, August). Attention-based Broad Self-guided Network for Low-light Image Enhancement. In *2022 26th International Conference on Pattern Recognition (ICPR)* (pp. 31-38). IEEE.
- Guo, C., Li, C., Guo, J., Loy, C. C., Hou, J., Kwong, S., & Cong, R. (2020). Zero-reference deep curve estimation for low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 1780-1789).
- Guo, X., Li, Y., & Ling, H. (2016). LIME: Low-light image enhancement via illumination map estimation. *IEEE Transactions on image processing*, 26(2), 982-993.
- Hao, S., Han, X., Guo, Y., Xu, X., & Wang, M. (2020). Low-light image enhancement with semi-decoupled decomposition. *IEEE transactions on multimedia*, 22(12), 3025-3038.
- Hou, Q., Zhou, D., & Feng, J. (2021). Coordinate attention for efficient mobile network design. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 13713-13722).
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7132-7141).
- Jiang, Y., Gong, X., Liu, D., Cheng, Y., Fang, C., Shen, X., ... & Wang, Z. (2021). Enlightengan: Deep light enhancement without paired supervision. *IEEE transactions on image processing*, 30, 2340-2349.+

- Kim, B., Lee, S., Kim, N., Jang, D., & Kim, D. S. (2022). Learning color representations for low-light image enhancement. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (pp. 1455-1463).
- Li, L., Wang, R., Wang, W., & Gao, W. (2015, September). A low-light image enhancement method for both denoising and contrast enlarging. In *2015 IEEE international conference on image processing (ICIP)* (pp. 3730-3734). IEEE.
- Li, M., Liu, J., Yang, W., Sun, X., & Guo, Z. (2018). Structure-revealing low-light image enhancement via robust retinex model. *IEEE Transactions on Image Processing*, 27(6), 2828-2841.
- Liang, D., Li, L., Wei, M., Yang, S., Zhang, L., Yang, W., ... & Zhou, H. (2022, June). Semantically contrastive learning for low-light image enhancement. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 36, No. 2, pp. 1555-1563).
- Lore, K. G., Akintayo, A., & Sarkar, S. (2017). LLNet: A deep autoencoder approach to natural low-light image enhancement. *Pattern Recognition*, 61, 650-662.
- Lu, K., & Zhang, L. (2020). TBEFN: A two-branch exposure-fusion network for low-light image enhancement. *IEEE Transactions on Multimedia*, 23, 4093-4105.
- Lv, F., Li, Y., & 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.
- Park, J., Woo, S., Lee, J. Y., & Kweon, I. S. (2018). Bam: Bottleneck attention module. *arXiv preprint arXiv:1807.06514*.
- Qu, Y., & Ou, Y. (2020). LEUGAN: low-light image enhancement by unsupervised generative attentional networks. *arXiv preprint arXiv:2012.13322*.
- Ren, W., Liu, S., Ma, L., Xu, Q., Xu, X., Cao, X., ... & Yang, M. H. (2019). Low-light image enhancement via a deep hybrid network. *IEEE Transactions on Image Processing*, 28(9), 4364-4375.
- Roy, A. G., Navab, N., & Wachinger, 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* (pp. 421-429). Springer International Publishing.
- Shen, L., Yue, Z., Feng, F., Chen, Q., Liu, S., & Ma, J. (2017). Msr-net: Low-light image enhancement using deep convolutional network. *arXiv preprint arXiv:1711.02488*.
- Tanaka, M., Shibata, T., & Okutomi, M. (2019, January). Gradient-based low-light image enhancement. In *2019 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 1-2). IEEE.
- Tao, L., Zhu, C., Xiang, G., Li, Y., Jia, H., & Xie, X. (2017, December). LLCNN: A convolutional neural network for low-light image enhancement. In *2017 IEEE Visual Communications and Image Processing (VCIP)* (pp. 1-4). IEEE.

- Wang, L. W., Liu, Z. S., Siu, W. C., & Lun, D. P. (2020). Lightning network for low-light image enhancement. *IEEE Transactions on Image Processing*, 29, 7984-7996.
- Wang, Q., Wu, B., Zhu, P., Li, P., Zuo, W., & 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* (pp. 11534-11542).
- Wang, W., Wu, X., Yuan, X., & Gao, Z. (2020). An experiment-based review of low-light image enhancement methods. *Ieee Access*, 8, 87884-87917.
- Wang, Y., Wan, R., Yang, W., Li, H., Chau, L. P., & Kot, A. (2022, June). Low-light image enhancement with normalizing flow. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 36, No. 3, pp. 2604-2612).
- Wei, C., Wang, W., Yang, W., & Liu, J. (2018). Deep retinex decomposition for low-light enhancement. *arXiv preprint arXiv:1808.04560*.
- Wei, X., Zhang, X., & Li, Y. (2022, September). Tsn-ca: A two-stage network with channel attention for low-light image enhancement. In *International Conference on Artificial Neural Networks* (pp. 286-298). Cham: Springer Nature Switzerland.
- Xu, K., Chen, H., Xu, C., Jin, Y., & 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.
- Yang, W., Wang, S., Fang, Y., Wang, Y., & Liu, J. (2020). From fidelity to perceptual quality: A semi-supervised approach for low-light image enhancement. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 3063-3072).
- Ying, Z., Li, G., Ren, Y., Wang, R., & Wang, W. (2017). A new low-light image enhancement algorithm using camera response model. In *Proceedings of the IEEE international conference on computer vision workshops* (pp. 3015-3022).
- Zhang, Y., Di, X., Zhang, B., & Wang, C. (2020). Self-supervised image enhancement network: Training with low light images only. *arXiv preprint arXiv:2002.11300*.
- Zhou, F., Sun, X., Dong, J., & Zhu, X. X. (2023). SurroundNet: towards effective low-light image enhancement. *Pattern Recognition*, 109602.
- Zhu, M., Pan, P., Chen, W., & Yang, Y. (2020, April). Eemefn: Low-light image enhancement via edge-enhanced multi-exposure fusion network. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 34, No. 07, pp. 13106-13113).
- Çalışkan, A. (2023). Detecting human activity types from 3D posture data using deep learning models. *Biomedical Signal Processing and Control*, 81, 104479.
- Çalışkan, A. (2023). Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network. *Transactions of the Institute of Measurement and Control*, 45(5), 975-985.