



Multi-exposure image fusion using convolutional neural network

Harun Akbulut^{1*}, Veysel Aslantaş²

¹Department of Computer Technologies, Boğazlıyan Vocational School, Yozgat Bozok University, Yozgat, 66400, Türkiye

²Department of Computer Engineering, Faculty of Engineering, Erciyes University, Kayseri, 38280, Türkiye

Highlights:

- A novel, simple and effective pre-trained CNN model for multi-exposure image fusion
- Obtaining fusion maps using pre-trained CNN model
- Eliminating the saw-tooth effect on the fused image using weighted fusion rule

Keywords:

- Multi-exposure image fusion
- Convolution neural network
- Weighted fusion rule
- Quality metrics

Article Info:

Research Article

Received: 02.02.2022

Accepted: 16.06.2022

DOI:

10.17341/gazimmfd.1067400

Correspondence:

Author: Harun Akbulut

e-mail:

harun.akbulut@yobu.edu.tr

phone: +90 354 290 3002

Graphical/Tabular Abstract

In this study, a new multi-exposure image fusion (MEF) method using convolutional neural network (CNN) is proposed. The method constructs a single high dynamic range (HDR) image of a scene from its two or more low dynamic range (LDR) images. The proposed method flowchart is shown in Figure A.

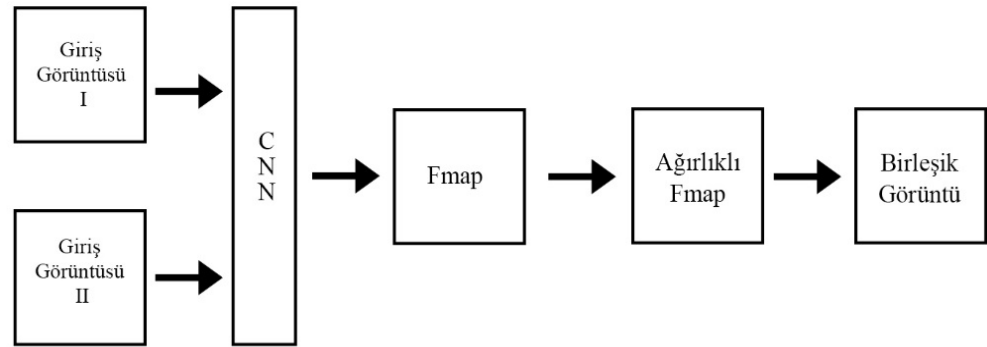


Figure A. The proposed method

Purpose: The aim of the study is to obtain a new single high dynamic range image of a scene from the low dynamic range images of the same scene.

Theory and Methods: In this study, a new MEF method using CNN is proposed. The proposed method is reasonably fast and effective. Since it is a costly task to create a new CNN model, a pre-trained CNN model was used. First, the fusion map employed for constructing the fused image was obtained from the source images using a pre-trained CNN model. The fusion map is then used to compute the fused image. In order to eliminate the saw-tooth effect in the fused images, weighting was performed on the fusion map. After that, a well-exposed fused image was constructed using the weighted fusion map.

Results: The proposed method was applied to the MEF datasets, which are widely used in the literature, and the fused images obtained were evaluated using well-known quality metrics. The developed technique and other well-known MEF techniques are compared in terms of quantitative and visual evaluation.

Conclusion: Convolution neural network, widely used and effective in multidimensional and nonlinear problem solutions, gives reasonably fast and effective results for multi-exposure image fusion. The results obtained show the feasibility of the proposed technique.



Evrişimli sinir ağı kullanarak çoklu-pozlamalı görüntü birleştirme

Harun Akbulut^{1*}, Veysel Aslantaş²

¹Yozgat Bozok Üniversitesi, Boğazlıyan Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, 66400 Boğazlıyan Yozgat, Türkiye

²Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 38280 Talas Kayseri, Türkiye

Ö N E Ç İ K A N L A R

- Çoklu-pozlamalı görüntü birleştirme için yeni, basit ve etkili CNN model
- Ön-egitilmiş CNN kullanarak birleştirme haritası oluşturma
- Ağırlıklı birleştirme kuralı kullanarak birleştirilmiş görüntü üzerindeki testere-dişi etkisini bertaraf etme

Makale Bilgileri

Araştırma Makalesi

Geliş: 02.02.2022

Kabul: 16.06.2022

DOI:

10.17341/gazimmfd.1067400

Anahtar Kelimeler:

Çoklu-pozlamalı görüntü birleştirme, evrişimli sinir ağı, ağırlıklandırılmış görüntü birleştirme, kalite metrikleri

ÖZ

Aynı sahneye ait iki ya da daha fazla düşük dinamik alana (LDR) sahip görüntülerden yüksek dinamik alana (HDR) sahip tek bir görüntü elde etme yöntemlerine çoklu-pozlamalı görüntü birleştirme (MEF) denir. Bu çalışmada MEF için derin öğrenme (DL) modellerinden evrişimli sinir ağı (CNN) kullanan yeni bir yöntem önerilmiştir. Önerilen yöntemde ilk adımda CNN modeli kullanılarak kaynak görüntülerden birleştirme haritası (f_{map}) elde edilmiştir. Birleştirilmiş görüntülerde testere-dişi etkisini ortadan kaldırmak için f_{map} üzerinde ağırlıklandırma işlemi gerçekleştirilmiştir. Daha sonra ağırlıklandırılmış f_{map} kullanılarak her tarafı iyi pozlanmış birleştirilmiş görüntüler oluşturulmuştur. Önerilen yöntem literatürde yaygın olarak kullanılan MEF veri setlerine uygulanmış ve elde edilen birleştirilmiş görüntüler kalite metrikleri kullanılarak değerlendirilmiştir. Önerilen yöntem ve diğer iyi bilinen görüntü birleştirme yöntemleri, görsel ve niceliksel değerlendirme açısından karşılaştırılmıştır. Elde edilen sonuçlar, geliştirilen tekniğin uygulanabilirliğini göstermektedir.

Multi-exposure image fusion using convolutional neural network

H I G H L I G H T S

- A novel, simple and effective pre-trained CNN model for multi-exposure image fusion
- Obtaining fusion maps using pre-trained CNN model
- Eliminating the saw-tooth effect on the fused image using weighted fusion rule

Article Info

Research Article

Received: 02.02.2022

Accepted: 16.06.2022

DOI:

10.17341/gazimmfd.1067400

Keywords:

Multi-exposure image fusion, convolution neural network, weighted fusion rule, quality metrics

ABSTRACT

The method of obtaining a single high dynamic range (HDR) image from two or more low dynamic range (LDR) images of the same scene is called multi-exposure image fusion (MEF). In this study, a new MEF method using convolutional neural network (CNN) from deep learning (DL) models is proposed. In the proposed method, firstly, the fusion map (f_{map}) was computed from source LDR images using the CNN model. In order to eliminate the saw-tooth effect in the fused images, weighting was performed on the f_{map} . Then, a well-exposed fused image was constructed using the weighted f_{map} . After that, the proposed method was applied to the MEF datasets, which are widely used in the literature, and the fused images obtained were evaluated using well-known quality metrics. The developed technique and other well-known MEF techniques are compared in terms of quantitative and visual evaluation. The results obtained show the feasibility of the proposed technique.

1. Giriş (Introduction)

Görüntü birleştirme, son zamanlarda görüntü analizi ve bilgisayarlı görü sahalarında önemli bir çalışma alanı haline gelmiştir [1, 2]. Bu teknik ile ya farklı sensörlerle [3, 4] ya da aynı sensörün farklı parametre veya konumlanmasıyla [5-7] aynı çevreden alınan birden fazla görüntü daha fazla bilgi içeren bir tek görüntü halinde birleştirilir. Böylece hem insan hem de makine analizi açısından daha kullanışlı bir görüntü elde edilir. Elde edilen bu görüntülerin kalite değerlendirmesi kalite metrikleri kullanılarak yapılır [8-10]. Birleştirilmiş görüntü; tıp, robotik, güvenlik, bölütleme, özellik çıkarma, nesne tanıma vs. gibi birçok uygulama sahasında kullanılmaktadır [11].

Doğal bir sahne yüksek dinamik alan (HDR) görüntüsü içermektedir. Günümüzde yaygın olarak kullanılan dijital kamera sensörleri ise düşük dinamik alan (LDR) görüntüsü yakalayabilmektedir. Bu sebepten bu sensörler doğal bir sahnenin görüntülenmesinde yetersiz kalmaktadır. Bu sensörler kullanılarak elde edilen görüntülerin bazı kısımları iyi bir şekilde pozlanabilirken bazı kısımları az ya da aşırı pozlanabilmektedir. Böylece elde edilen görüntülerde arzu edilmeyen aşırı karanlık veya aşırı aydınlık kısımlar meydana gelebilmektedir. Bu arzu edilmeyen kısımları barındırmayan her tarafı iyi pozlanmış görüntü ise hem insan algısı hem de bilgisayarlı görü uygulamaları için büyük önem arz etmektedir [10].

Bu problem HDR görüntüleme aygıtları kullanılarak çözülebilmeye rağmen onların hem yüksek maliyetlerinden hem de kullanımlarının profesyonellik gerektirmesinden genel olarak tercih edilmemektedir. Diğer taraftan bu problem LDR görüntülerden HDR görüntü elde etme yöntemleriyle de çözülebilmektedir. Temel olarak bu yöntemler ton eşleştirme (TM) ve görüntü birleştirmeye (IF) dayalı yöntemler olmak üzere iki kısma ayrılabilir. Literatürde birçok etkili TM yöntemleri sunulmasına rağmen IF yöntemleri, TM yöntemlerine göre genellikle daha iyi sonuçlar verdiği görülmektedir [10].

Aynı sahneye ait iki ya da daha fazla LDR görüntülerden her tarafı iyi pozlanmış tek bir HDR görüntü elde etme yöntemleri çoklu-pozlamalı görüntü birleştirme (MEF) olarak adlandırılabilir [12, 13]. MEF yöntemleri LDR görüntü elde etme yöntemlerine göre tekli ve çoklu sensör MEF olmak üzere temelde iki sınıfta incelenebilir. Tekli sensör MEF'de aynı sahneye ait iki ya da daha fazla LDR görüntülerin tek bir aygıttan farklı parametre değerleri kullanarak elde edilirken çoklu sensör MEF'de ise birden fazla sensör kullanarak elde edilir [14]. MEF yöntemleri, dönüşüm ve resim uzayı tabanlı yöntemler olmak üzere temelde iki sınıfta incelenebilir [15].

Dönüşüm tabanlı yöntemlerde ilk olarak kaynak görüntüler dönüşüm işlemine tabi tutulur. Elde edilen dönüşüm katsayıları kullanarak birleşik dönüşüm görüntüsü elde edilir. Ardından ters dönüşüm işlemi uygulanarak birleştirilmiş görüntü elde edilir. İlk öncü dönüşüm tabanlı MEF yöntemi Mertens vd. [16] tarafından sunulmuştur. Bu çalışmada kaynak görüntülerden elde edilen kontrast, koyuluk (saturation) ve iyi pozlanmışlık değerleri Laplacian piramit dönüşümü kullanılarak her tarafı iyi pozlanmış görüntü elde edilmiştir. Yine benzer şekilde Malik vd. [17] tarafından dalgacık dönüşüm, Wang vd. [18] tarafından da kaymadan bağımsız ayrık dalgacık dönüşüm tabanlı MEF yöntemleri önerilmiştir. Literatürde dönüşüm tabanlı birçok MEF yöntemi sunulmuştur [19-22]. Dönüşüm tabanlı yöntemlerde dönüşüm katsayıları görüntünün tamamına uygulanacağından dolayı, birleştirme işlemi esnasında kaynak görüntülerdeki kaymalardan ve gürültülerden oldukça fazla etkilenecektir. Böylece elde edilen görüntüde yapay görüntü ihtiva eden bölgeler ve özellikle de renk bozulmaları oluşabilmektedir. Ayrıca bu yöntemlerde görüntüler üzerinde dönüşüm-ters dönüşüm işlemleri yapıldığından dolayı hem

işlem zamanı hem de işlem maliyeti artacaktır [6]. Dönüşüm tabanlı yöntemlerin bu dezavantajlarını ortadan kaldırmak için resim (piksel) uzayı tabanlı yöntemler sunulmuştur.

Resim uzayı tabanlı yöntemlerin temel amacı kaynak görüntülerde bulunan iyi pozlanmış piksellerin birleştirilmiş görüntüye taşınmasıdır. Resim uzayı tabanlı yöntemler de piksel tabanlı ve bölge tabanlı olmak üzere temelde iki grupta incelenebilir [15]. En temel piksel tabanlı yöntem olarak karşılıklı piksel gri seviye değerlerinin ağırlıklı ortalamaları alınarak gerçekleştirilir. Bu yöntemde genellikle kaynak görüntüler üzerindeki karşılıklı piksel kontrast, parlaklık ve gradyan bilgisi kullanılmaktadır. Literatürde birçok piksel tabanlı MEF yöntemi önerilmiştir [23-28]. Piksel tabanlı MEF yönteminin uygulaması basit olmasına rağmen kaynak görüntüler üzerinde sadece karşılıklı piksel değerleriyle işlem yapılması gürültülü ve istenmeyen yapay görüntülerin ortaya çıkmasına sebep olmaktadır. Dolayısıyla daha iyi sonuçlar elde edebilmek için birleştirme öncesi kaynak görüntüler üzerinde ve birleştirme sonrası birleşik görüntü üzerinde ek işlemlerin yapılmasına ihtiyaç duyulmaktadır. Bu problemi ortadan kaldırmak için bölge temelli MEF yöntemleri önerilmiştir.

Bölge temelli MEF yöntemlerinde kaynak görüntüler üzerinde bulunan iyi pozlanmış blok ya da bölgeler birleştirilmiş görüntüye taşınır. Böylece her tarafı iyi pozlanmış görüntü elde edilmesi hedeflenmektedir. Blok-temelli MEF yönteminin öncüsü olarak Goshtasby'nin çalışması gösterilebilir. Goshtasby'nin çalışmasında kaynak görüntüler birbirlerinin üzerine gelmeyecek ve aralarında boşluk olmayacak şekilde düzenli olarak sabit boyutlu bloklara ayrılır. Daha sonra iyi pozlanmış blok parçacıkları entropi kıstas işlevi kullanarak belirlenmiştir. Blokların boyutları ve birleştirme ağırlıkları gradyan-tırmanış (gradient-ascend) algoritması kullanarak optimize edilmiştir [29]. Diğer bir blok-tabanlı MEF yöntemi Kong vd. tarafından önerilmiştir. Bu çalışmada, Goshtasby'nin çalışmasından farklı olarak birleştirme ağırlıklarının hesaplanması için gradyan-tırmanış algoritması yerine genetik algoritma kullanılmıştır [30].

Geleneksel blok temelli (TBB) yöntemlerde kaynak görüntülerden iyi pozlanmışlık değeri daha yüksek olan bloklar birleştirilmiş görüntüye taşınır. Ancak bu bloklar iyi pozlanmış kısımların yanında aşırı ya da az pozlanmış kısımları da ihtiva edebilir. Böylece birleştirilmiş görüntüler de arzu edilmeyen aşırı ya da az pozlanmış kısımlar meydana gelebilir. Bu dezavantajı ortadan kaldırmak için serbest bölge seçimine dayalı bölge temelli MEF yöntemleri önerilmiştir. Wang vd. [12] tarafından süper-piksel bölütleme kullanarak bölge temelli MEF yöntemi önerilmiştir. Önerilen yöntemde ilk olarak kaynak görüntüler süper-piksel bölütleme yöntemi ile bölütlenmiştir. Ardından her bölütün sinyal gücü, görüntü yapısı ve yoğunluk bilgileri hesaplanmıştır. Son olarak elde edilen görüntüde testere-dişi etkisini ortadan kaldırmak için kılavuzlu (guided) filtre kullanarak birleştirme işlemi yapılmıştır. Bölge temelli MEF yöntemlerinde iyi pozlanmış bölge tespitlerinin çok iyi belirlenmesi gerekmektedir. Aksi durumda elde edilen birleştirilmiş görüntü aşırı aydınlık veya karanlık bölgeler içerecektir. Literatürde etkili bölge temelli birçok MEF yöntemi sunulmuştur [31-33].

Son zamanlarda MEF için çok boyutlu ve doğrusal olmayan problemlerin çözümünde hızlı ve daha etkili sonuçlar veren derin öğrenme (DL) yöntemleri popüler hale gelmiştir. DL yöntemleri denetimli ve denimsiz DL olmak üzere temelde iki sınıfta incelenebilir. Ma vd. [34] tarafından denetimli MEF-Net yöntemi önerilmiştir. Bu yöntemde ağ alt-örnekleme kaynak görüntüler tarafından beslenerek birleştirme ağırlıkları oluşturulmuştur. Alt-örnekleme kaynak görüntülerle ağ beslenerek ağımlı hesaplama maliyeti azaltılmıştır. Özellikle çıkarımında komşu piksel bilgilerinden yararlanılmadığı için piksel tabanlı yöntemlerin dezavantajlarına

sahip olduğu söylenebilir. Xu vd. [35] MEF-GAN yöntemini önermişlerdir. HDR görüntü elde etmek için iki ağ kullanılmıştır. Bunlardan ilki birleştirilmiş görüntüyü elde etmek için kaynak görüntülere dayalı eğitilirken diğeri ise referans HDR görüntüden elde edilen birleştirilmiş görüntünün farklılığına dayalı eğitilmiştir. Denetimli DL yöntemleri, ağı eğitmek için büyük miktarda HDR görüntü gerektirir. Ayrıca birleştirilmiş görüntünün kalitesi de ağı eğitilmesi esnasında referans olarak kullanılacak mevcut HDR görüntü kaliteleri ile sınırlı olacaktır. Böylece bu yöntemin başarımı mevcut HDR görüntülerin kaliteleriyle sınırlı olacaktır. Bu dezavantajı ortadan kaldırmak için denetimsiz DL yöntemleri önerilmiştir. Prabhakar vd. [36] tarafından uygunluk işlevi olarak yapısal benzerlik kalite metriğini (SSIM) kullanan MEF için ilk denetimsiz DL yöntemi önerilmiştir. Uygunluk işlevi her pikselin önemini hesaba katmadığından dolayı elde edilen görüntülerde özellikle aşırı ve az pozlanmış bölge geçişlerinde yapay görüntüler elde edilmiştir. Ayrıca kaynak görüntü için yöntemde sadece iki görüntü kullanılmıştır. Qi vd. [37] tarafından MEF için uygunluk işlevi olarak SSIM kullanan DL yöntemi önerilmiştir. Onların yönteminde Prabhakar ve arkadaşlarının [36] yönteminin dezavantajını gidermek için uygunluk işlevi optimizasyonu kullanılmıştır. Ayrıca kaynak görüntü olarak ikiden fazla girişe de izin verilmiştir. DL yöntemleri kullanılarak etkili HDR görüntü elde edilmesine rağmen kaynak görüntülerin ihtiva etmediği yapay görüntü elde edilme dezavantajı hala devam etmektedir. Dolayısıyla DL tabanlı MEF yöntemlerinin geliştirilmesi gerekmektedir. Önerilen birçok DL yöntemlerinin en önemli dezavantajı birleştirilmiş görüntülerde yapay görüntü ihtiva eden bölgelerin bulunmasıdır. Son yıllarda evrişimli sinir ağları, metin görüntüleri üzerinde karakter tanımadan [38], ağaç [39], mermer-granit [40] çeşitlerinin sınıflandırılmasına ve Corana virüs hastalığının teşhisine [41] kadar birçok alanda kullanılmaya başlamıştır. Bu çalışmada DL modellerinden ön eğitilmiş CNN modeli [42] kullanan basit ve hızlı bölge temelli MEF yöntemi önerilmiştir. Önerilen yöntemde ilk olarak kaynak görüntüler CNN modeli vasıtasıyla bölütlenerek birleştirme haritası f_{map} oluşturulur. Elde edilen birleştirme haritası kullanılarak kaynak görüntüler doğrudan birleştirildiğinde testere-dişi etkisi oluşmaktadır. Bu etkiyi ortadan kaldırmak için ağırlıklı birleştirme kuralı uygulanarak her tarafı iyi pozlanmış görüntü elde edilmiştir. Önerilen yöntem literatürdeki birçok çalışmaya göre çok daha hızlı, basit ve elde edilen sonuçların da MEF için tatmin edici olduğu görülmüştür. Makale takip eden şekilde düzenlenmiştir: İkinci bölümde CNN, üçüncü bölümde önerilen yöntem anlatılacaktır. Dördüncü bölümde önerilen yöntem ile elde edilen deneysel sonuçlar verilecektir. Sonuç kısmında çalışmanın bir değerlendirilmesi yapılacaktır.

2. Evrişimli Sinir Ağı (Convolutional Neural Network-Cnn)

DL özellikle sınıflandırma, tanıma ve tespit için kullanılan son yıllarda karmaşık, çok boyutlu ve doğrusal olmayan birçok problem çözümünde araştırmacılar tarafından yaygın ve etkili bir biçimde kullanılmaya başlayan bir ya da birden fazla çok katmanlı yapay sinir ağı modeli olarak tanımlanabilir [43]. Konvolüsyonel Sinir Ağları (CNN) bilgisayarlı görü uygulamalarında en başarılı sonucu veren ve en yaygın olarak kullanılan DL mimarisidir. En yaygın olarak kullanılan CNN modelleri AlexNet [44], VGGNet [45], GoogLeNet [46], ResNet'tir [47] ve SegNet [48] olarak ifade edilebilir. CNN modelleri farklı mimariye sahip olmakla birlikte konvolüsyon, havuzlama (pooling), tam bağlı (full-connected) katmanlardan ve ReLU aktivasyon işlevi elemanlarından oluşur [49]. Temel CNN yapısı Şekil 1'de gösterilmiştir.

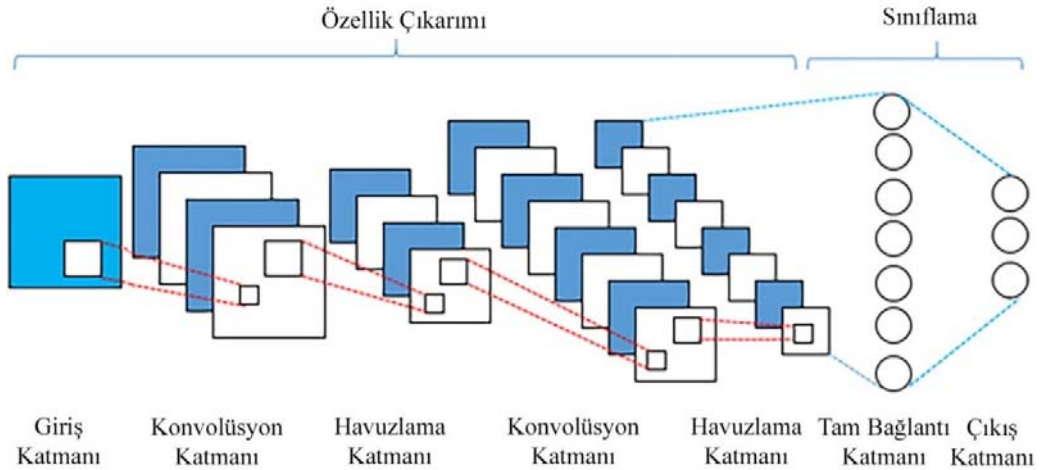
2.1. Konvolüsyon Katmanı (Convolution Layer)

Derin öğrenme ağlarının ilk katmanı olan bu katmanda girdi görüntüsünün gri piksel matrisi üzerinde bir filtre gezdirilerek girdi görüntülerden özellik çıkarımı elde edilmeye çalışılır. Elde edilen bu matrisler öznitelik haritası ya da aktivasyon haritası olarak adlandırılır. Bu filtreler kullanılarak görüntü üzerindeki özellikler daha belirgin hale getirilerek kenar tespiti, görüntü keskinleştirme ve görüntü bulanıklaştırma vs. gibi birçok işlemler yapılabilmektedir. Kaynak matris üzerinde konvolüsyon işlemi uygulanırken filtrenin kaynak matrisler üzerinde kaç piksel kayacağı adım (stride) değeri ile belirlenmektedir. Konvolüsyon katmanında kullanılan adım sayısı arttıkça elde edilen matrisin boyutu daha küçük hale gelecektir. Konvolüsyon katmanını daha iyi anlamak için 7x7 boyutlarına sahip bir matris, matrise uygulanan 3x3 konvolüsyonel filtre ve 1 ve 2 adımda konvolüsyon uygulanmış matris Şekil 2'de gösterilmiştir.

Ayrıca kaynak matrise konvolüsyon işlemi uygulandığında kenar piksellerdeki bilgileri kaybetme durumu ortaya çıkmaktadır. Bu dezavantajı ortadan kaldırmak için dolgulama (padding) işlemi uygulanmaktadır. Literatürde 0-dolgulama, 1-dolgulama, dairesel dolgulama ve simetrik dolgulama yöntemleri yaygın olarak kullanılan dolgulama yöntemleri olarak listelenebilir [50].

2.2. Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanının görevi kendisine gönderilen girdi matrisindeki öne çıkan özellikleri daha belirgin hale getirmek, önemsiz özellikleri göz ardı etmek ve matris boyutunun azaltılmasını



Şekil 1. Temel CNN yapısının şematik gösterimi (Basic CNN structure)

sağlayarak hesaplama maliyetini azaltmaktadır. Böylece ağıın hem parametre sayısı azalacak hem de öğrenme yeteneğinin geliştirilmesine katkı sağlanırken ağıın ezberlemesini azaltacaktır. En yaygın kullanılan havuzlama yöntemleri, ortalama havuzlama (avg-pooling), en yüksek havuzlama (max-pooling) ve toplam havuzlama (sum-pooling) yöntemleridir [50]. Şekil 2'deki sonuç matrislerine en büyük ve en küçük havuzlama yöntemlerinin uygulanmasıyla elde edilen sonuçlar Şekil 3'te gösterilmiştir.

2.3. Tam bağlantılı katman (Fully connected layer)

Havuzlama katmanı ve ReLU aktivasyon işlevinden sonra gelen tam bağlantılı katman, kendinden önceki tüm alanlara bağlıdır. Bu aşamadan önce matris halinde bulunan girdi matrislerine bir düzleştirme (flattening) işlemi uygulanarak tam bağlantılı katmanın girdi matrisi hazırlanmış olur. Düzleştirme işlemi, Şekil 3'te verilen en büyük havuzlama işlemi ile hesaplanan matrise uygulandığında elde edilen sonuç Şekil 4'te gösterilmiştir. Farklı CNN mimarilerinde bir ya da birden fazla tam bağlantılı katman kullanılabilir. Bazı CNN mimarilerinde bu ağıdan sonra bir seyreltme (dropout) katmanı kullanılmaktadır. Bu katmanda, tam bağlantılı katmandaki rastgele seçilen nöronların ağırlıkları sıfıra eşitlenerek ağıın ezberlemesinin önüne geçilmektedir. Bu katmandan sonra çıkış katmanı gelmektedir. Çıkış katmanında bir sınıflama yapmak yine bir aktivasyon işlevine ihtiyaç duyulur. Bu katmanda son zamanlarda yaygın olarak softmax aktivasyon işlevi kullanılmaktadır [50].

2.4. ReLU aktivasyon işlevi (ReLU activation function)

CNN ağılarında ağıın öğrenmesine doğrusal olmayan bir yaklaşım sergilemek adına konvolüsyon katmanlarından sonra genellikle doğrusal olmayan bir aktivasyon işlevi kullanılır.

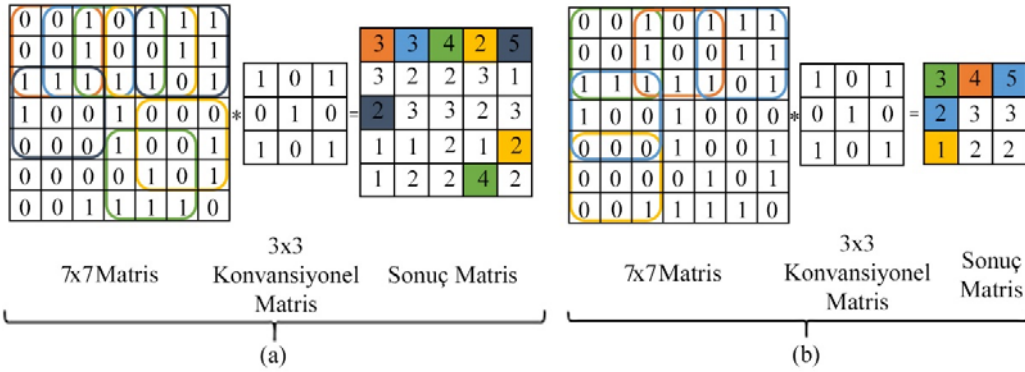
Böylece ağı doğrusal olmayan bir öğrenme özelliği kazandırılır. Sigmoid, tanjant hiperbolik, softmax ve ReLU yaygın kullanılan aktivasyon işlevlerinden bazılarıdır. ReLU son zamanlarda DL ağılarında yaygın olarak kullanılan doğrusal olmayan bir aktivasyon işlevidir. Eş. 1'de ReLU aktivasyon işlevinin matematiksel formülü verilmiştir.



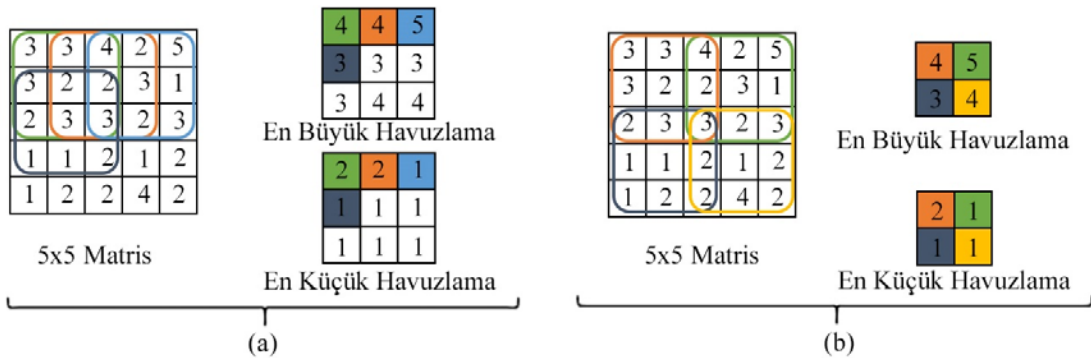
Şekil 4. Düzleştirme işlemi. (Flattening operation)

$$ReLU(x) = \begin{cases} 0, & \text{eğer } x \leq 0 \\ x, & \text{eğer } x > 0 \end{cases} \quad (1)$$

ReLU aktivasyon işlevinin sigmoid ve tanjant hiperbolik aktivasyon işlevlerinden farkı, negatif değere sahip nöronların ağırlıklarının 0'a eşitlenerek sadece pozitif nöronları aktive eder. Ayrıca hesaplama maliyeti de diğer aktivasyon işlevlerinden daha düşüktür. ReLU aktivasyon işlevi kullanarak ağıın daha önce sahip olmadığı doğrusal olmayan özelliğe sahip olması sağlanır. Böylece doğrusal olmayan problem çözümlerinde daha iyi sonuçlar vermesi beklenir.



Şekil 2. Konvolüsyon işlemi: a) Bir piksel, b) İki piksel kaydırma (Convolution operation: a) One pixel, b) Two pixel stride)



Şekil 3. En büyük ve en küçük havuzlama işlemi: a) Bir piksel 3x3 havuzlama, b) İki piksel 3x3 havuzlama işlemi. (Max and min pooling operation: a) One stride 3x3 pooling, b) Two stride 3x3 pooling operation.)

3. Çoklu-Pozlanmış Görüntülerin Cnn Kullanarak Birleştirilmesi (Multi-Exposure Image Fusion Using Cnn)

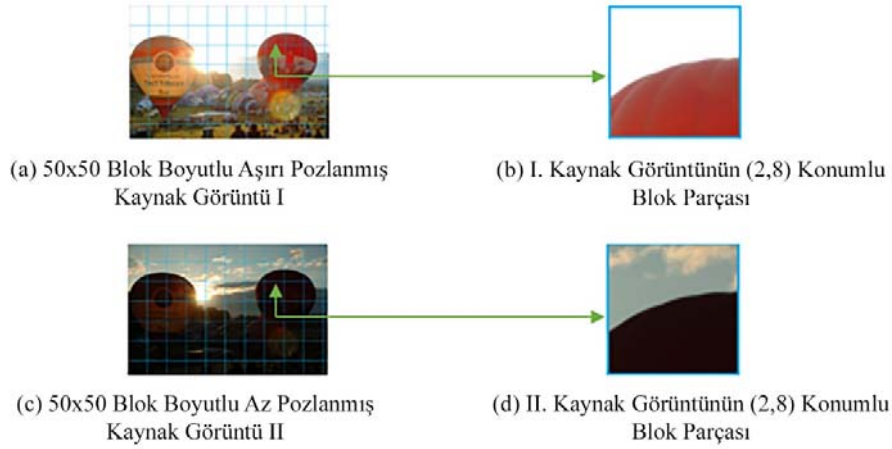
TBB yöntemlerinde kaynak görüntüler birbirlerinin üzerine gelmeyecek, aralarında boşluk olmayacak şekilde, düzenli olarak ve sabit boyutlu bloklara ayrılır (Şekil 5a-b). Kaynak görüntüler üzerindeki her bir blok karşılıklı olarak kıstas işlevleri kullanarak değerlendirilir. Literatürde birçok kıstas işlevi önerilmesine rağmen tüm görüntüler için iyi sonuçlar veren tek bir kıstas işlevi önerilmemiştir. Kıstas işlevi ile ilgili yapılan ön deneyler ve literatür araştırması sonucunda değiştirilmiş Laplacian toplamı (SML) kıstas işlevinin kullanılmasının daha uygun olacağı görülmüştür [7, 9]. Kıstas işlev değeri yüksek olan yani iyi pozlanmış blok parçası birleştirme haritasına işaretlenir. Ardından elde edilen birleştirme haritası kullanarak birleştirilmiş görüntü elde edilir. Kıstas işlevlerinin yanı sıra, TBB teknikleri, birleştirme sonuçlarını önemli ölçüde etkileyen uygun bir blok boyutunun belirlenmesini de gerektirir. Blok boyutu doğrudan kaynak görüntülerin içeriğine ve iyi pozlanmış, aşırı-az pozlanmış bölgelerine bağlıdır. Her uygulama için sabit bir blok boyutu geçerli olmayabilir. Bir blok, farklı aydınlatmalarda şartları altında bulunan nesnelerin görüntüsünü içeriyorsa, o zaman blok genel olarak kısmen iyi ve az pozlanmış bölgelere sahip olacaktır, bu da birleşik görüntünün yanlış hesaplanmasına sebep olur. Dolayısıyla blok boyutu seçimi sonuçların hassasiyetini oldukça etkilemektedir. Blok boyutu, kıstas işlevlerinin blokların pozlanma kalitesini daha doğru bir şekilde ölçmesine izin verecek kadar büyük ve kaynak görüntülerin sadece iyi ve kötü pozlanmış kısımlarını ihtiva edecek şekilde bölünebilmesine imkân verecek kadar küçük olmalıdır.

Bu çalışma kapsamında blok boyutunun sonuç üzerindeki etkisi, "Balon" veri seti [51] ve Matlab programı kullanarak bir örnek ile Şekil 5'te gösterilmiştir. Şekil 5b ve Şekil 5d'de görüldüğü gibi TBB yöntemlerinde (2,8) konumundaki blok parçalarının kıstas işlevi sonucunda hangi blok parçası seçilirse seçilsin sonuç olarak hem iyi pozlanmış hem de kötü pozlanmış bölgeler ihtiva edecektir. Bu problemi ortadan kaldırmak için ilk akla gelen çözüm, blok boyutunun düşürülmesi olabilir. Ancak blok boyutu azaldığı zaman kıstas işlevi doğru sonuçlar üretemeyecek ve böylece yöntemin başarımı azalacaktır. Diğer taraftan blok boyutu azaldığı için blok sayısı artacak ve buna paralel olarak yöntemin hesaplama maliyeti de artacaktır. Blok boyutunun büyük olması durumunda da, bloklar hem iyi ve hem kötü pozlanmış bölgeler ihtiva edecektir.

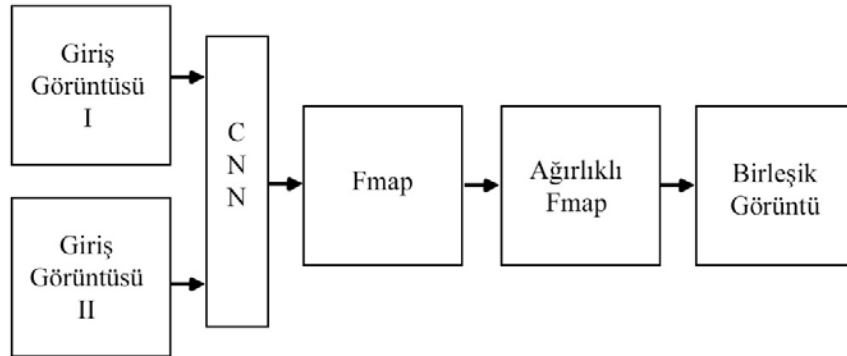
Bu sebeple, blok boyutunun seçimi kaçınılmaz olarak sezgisel seçimler gerektirir. Blok boyutlarının çok sayıda kombinasyonu mümkündür ve deneme yanılma yoluyla en uygun çözümleri bulmak oldukça zordur.

Birçok blok tabanlı etkili MEF yöntemi önerilmesine rağmen, MEF problemleri yapıları itibariyle doğrusal olmayan bir problem olduğu için, bu yöntemlerin tamamında bu problem mevcuttur. Bu problemi ortadan kaldırmak için çok boyutlu ve doğrusal olmayan problem çözümlerinde etkili sonuçlar veren DL yöntemlerinden CNN yöntemleri kullanılabilir. Bu çalışmada CNN yöntemi kullanılarak bölge temelli MEF yöntemi önerilmiştir. Önerilen yöntemin şematik gösterimi Şekil 6'da gösterilmiştir.

Şekil 6'dan da görüleceği üzere, önerilen yöntemde ilk olarak kaynak görüntüler CNN modeli kullanarak f_{map} oluşturulur. Kaynak



Şekil 5. TBB yönteminin dezavantajı. (Disadvantage of TBB methods)



Şekil 6. CNN kullanarak MEF yöntemi (MEF method using CNN)

görüntüler, elde edilen birleştirme haritası kullanılarak doğrudan birleştirildiğinde birleştirilmiş görüntüde Şekil 7'den de görüleceği üzere testere-dişi etkisi ortaya çıkmaktadır. Bu durumu ortadan kaldırmak için kaynak görüntüler birleştirme haritasındaki komşu piksel değerleri Eş. 2 kullanılarak ağırlıklı birleşme oranları hesaplanır.

$$w(i, j) = \frac{\sum_{x=i-a}^{i+a} \sum_{y=j-a}^{j+a} f_{map}(x, y)}{s^2} \quad (2)$$

Burada $w(i, j)$, ilgili piksel değerlerinin ağırlıklarını, s satır ve sütun yönündeki komşu piksel boyutunu ve $a=(s-1)/2$ belirtmektedir. Eş. 3 kullanılarak, kaynak görüntülerden ($I_1(i, j)$ ve $I_2(i, j)$) her tarafı iyi pozlanmış birleştirilmiş görüntü ($F(i, j)$) elde edilir.

$$F(i, j) = w(i, j) * I_1(i, j) + (1 - w(i, j)) * I_2(i, j) \quad (3)$$

Önerilen yöntemin sözde kodu Şekil 8'de verilmiştir.

3.1. Kalite Metrikleri (Quality metrics-QM)

Görüntünün değerlendirme işlemi araştırmacılar için zor bir problemdir. Literatürde birçok kıstas işlevi ve kalite metrikleri önerilmiştir. Ancak tüm görüntüler için en iyi sonucu veren bir kıstas işlevi ya da kalite metriği şu ana kadar önerilmemiştir. Bu sebepten dolayı görüntülerin birden fazla kıstas işlevi ya da kalite metrikleri ile ayrıca da görsel olarak değerlendirilmesi uygun olacaktır. Kalite metrikleri literatürde objektif ve referans tabanlı kalite metrikleri olmak üzere iki ana grupta sınıflandırılabilir. Bu çalışmada literatürde görüntü birleştirme için yaygın olarak kullanılan entropi (QM_E) [52], SML (QM_{SML}) [53], Chen-Blum (QM_{CB}) [54] ve yapısal benzerlik (QM_{SSIM}) [55] kalite metrikleri kullanılmıştır.

3.1.1. Entropi kalite metriği (Entropy quality metric)

Entropi bir görüntünün içerik bilgisini ölçen kalite metriği olup entropi değeri arttıkça görüntünün kalitesi de artmaktadır. Gri seviye bir görüntünün entropi değeri Eş. 4 kullanılarak elde edilir [52].

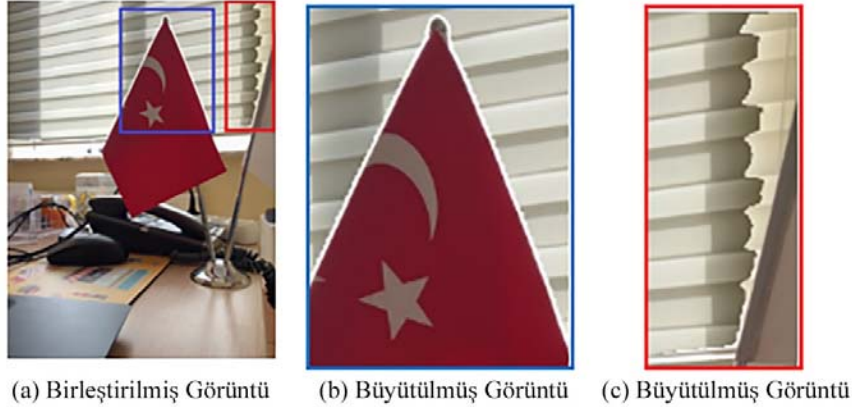
$$E(x) = - \sum_{i=0}^{L-1} P_F(x) \log_2 P_F(x) \quad (4)$$

burada, L griton sayısını, P birleştirilmiş resmin normalize edilmiş histogramını ifade etmektedir.

3.1.2. Değiştirilmiş Laplacian toplamı kalite metriği (Sum modified Laplacian quality metric)

Bir görüntünün kontrast değeri arttıkça sahip olduğu frekans değeri de artmaktadır. Böylece yüksek frekansların tespitinde yüksek geçiren filtre olan Laplacian operatörü kullanılabilir. Ancak yatay ve dikey yönlerdeki ikinci türevler farklı işaretlere sahip olabilir ve bu da bir işaretin diğerini iptal etmesine sebep olabilir. QM_{SML} , gerçek değerleri yerine, kısmi ikinci türevlerin mutlak değerlerinin toplanmasından dolayı normal Laplacian operatöründen farklıdır. QM_{SML} değeri yükseldikçe görüntünün kalite değeri de artacaktır. QM_{SML} değeri Eş. 5 kullanılarak hesaplanır.

$$\begin{aligned} \nabla^2 f(i, j) &= \left| \frac{\partial^2 f(i, j)}{\partial i^2} \right| + \left| \frac{\partial^2 f(i, j)}{\partial j^2} \right| \\ &= |2f(i, j) - f(i-1, j) - f(i+1, j)| \\ &\quad + |2f(i, j) - f(i, j-1) - f(i, j+1)| \\ SML &= \sum_i \sum_j \nabla^2 f(i, j) \end{aligned} \quad (5)$$



Şekil 7. Birleştirilmiş görüntüdeki testere-dişi etkisi (Saw-tooth effect on fused image)

Başla

- I_1 ve I_2 giriş görüntülerini oku,
- I_1 ve I_2 görüntülerinden CNN kullanarak f_{map} haritasını oluştur,
- Elde edilen f_{map} haritasına göre Eş. 2'yi kullanarak ağırlıklı birleştirme oranlarını hesapla,
- Eş. 3'ü kullanarak kaynak görüntülerden ağırlıklı birleştirilmiş görüntüyü oluştur.

Bitir.

Şekil 8. Önerilen yöntemin sözde kodu (Pseudo code of the proposed method)

3.1.3. Chen-Blum kalite metriği (Chen-Blum quality metric)

QM_{CB} [53] metriği, insan görme modellemesi tarafından motive edilen yeni bir algısal görüntü birleştirme kalite değerlendirmesi için geliştirilmiş bir metriktir. Genellikle birleştirilmiş görüntünün değerlendirilmesi için referans alınacak ideal bir görüntü elde etmek mümkün değildir. Bu sebeple, giriş görüntülerinden birleştirilmiş görüntüye aktarılan bilgi miktarı ölçülür. Bu metrik ile öncelikle belirli bir kontrast duyarlılığı işlevini kullanarak giriş görüntüleri filtrelenir, arkasından yerel kontrast hesaplanır, daha sonra bir belirginlik haritası (saliency map) oluşturulur ve en sonunda genel kalite değeri hesaplanır. Q_{CB} Eş. 6 ile tanımlanır:

$$Q_{CB} = \overline{Q_P}(i, j) \quad (6)$$

Q_P , her piksel için hesaplanan küresel kalite indeksidir. Q_P Eş. 7 ile verilir:

$$Q_P(i, j) = w_{I_1}(i, j) * Q_{I_1 F}(i, j) + w_{I_2}(i, j) * Q_{I_2 F}(i, j) \quad (7)$$

w_{I_1} ve w_{I_2} görüntü kontrastına bağlı belirginlik haritasını ifade eder. $Q_{I_1 F}$ ve $Q_{I_2 F}$, bilgi koruma değerleridir.

3.1.4. Yapısal benzerlik kalite metriği (Structural similarity index measure quality metric)

QM_{SSIM} , referans görüntü ve birleştirilmiş görüntü arasındaki benzerliği hesaplar. Eş. 8 kullanılarak hesap edilir [50].

$$QM_{SSIM}(I_1, I_2) = \frac{(2\mu_1\mu_2 + C_1)(2\sigma_{12} + C_2)}{(\mu_1^2 + \mu_2^2 + C_1) + (\sigma_1^2 + \sigma_2^2 + C_2)} \quad (8)$$

burada, μ_1 ve μ_2 , I_1 ve I_2 görüntülerinin ortalamasını, σ_1^2 ve σ_2^2 , I_1 ve I_2 görüntülerinin varyans değerlerini, σ_{12} , I_1 ve I_2 görüntülerinin kovaryans değerini ifade etmektedir. C_1 ve C_2 değişkenleri sırasıyla $C_1 = (k_1 L)^2$ ve $C_2 = (k_2 L)^2$ eşitlikleri kullanılarak hesaplanır. L griton sayısı olarak tanımlanır ($L = 255$). k_1 ve k_2 küçük sabitlerdir ($k_1 = 0.01$, $k_2 = 0.03$).

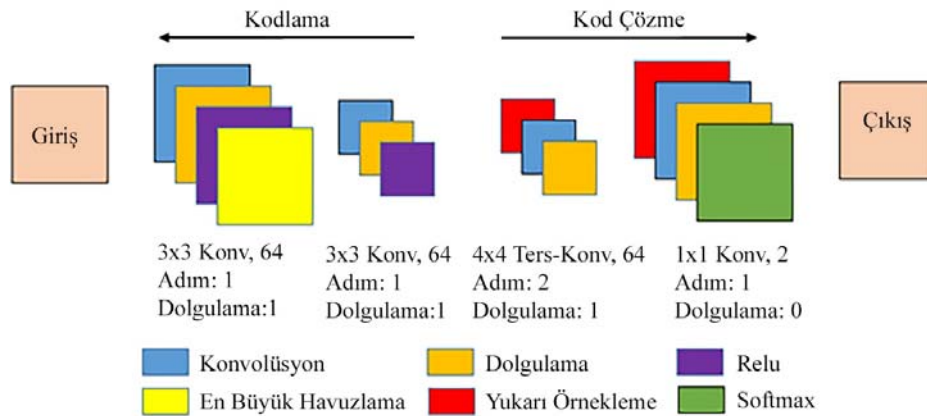
4. Deneysel Sonuçlar (Experimental Results)

Bu çalışmada CNN modeli kullanarak iyi pozlanmış bölge temelli yeni bir MEF yöntemi sunulmuştur. Yöntemin başarımını test etmek

için deneyler Windows 7 işletim sistemi, Intel Core 2.3 GHz işlemci, 8 Gb RAM ve Matlab R2018a programı kullanılarak yürütülmüştür. Deneylerde kullanılan görüntü setleri hem kendi elde ettiğimiz (Görüntü seti 1) hem de literatürde yaygın olarak kullanılan MEF görüntü setlerinden (Görüntü seti 2-5) [36, 51] seçilmiştir. Elde edilen birleştirilmiş görüntülerin kalite değerlendirilmesi için QM_E , QM_{SML} , QM_{CB} ve QM_{SSIM} kalite metrikleri kullanılmıştır.

CNN modellerinin eğitim/test veri setlerinin temini ve eğitim süreçlerinin hem uzun sürmesi hem de gelişmiş özelliğe sahip donanım elemanları gerektiğinden dolayı önceden eğitilmiş CNN modeli [42] kullanılmıştır. Önerilen CNN ağının mimarisi Şekil 9'da gösterilmektedir.

Birinci ve sonuncu katmanlarda sırasıyla giriş ve çıkış katmanı kullanılmış diğer katmanlarda ise konvolüsyon, ters-konvolüsyon, havuzlama, yukarı örnekleme katmanları, ReLU aktivasyon fonksiyonu ve piksel tabanlı sınıflama için softmax katmanı kullanılmıştır. Ağda kullanılan konvolüsyon filtreleri, adım, havuzlama ve dolgulama işlemleri Şekil 9'da gösterilmiştir. Birinci konvolüsyon katmanında 3x3 filtre, 1-adım ve ilk katmandan gelen bilgilerden daha fazla faydalanmak adına 1-dolgulama işlemi yapılmıştır. Böylece filtre boyutundan kaynaklanan bilgi kaybı önlenerek kaynak görüntüden maksimum bilgi ve öznetelik çıkarılması hedeflenmektedir. Konvolüsyon katmanından sonra ReLU aktivasyon işlevi kullanılarak problem çözümü için doğrusal olmayan bir yaklaşım sergilenmiştir. Birinci ReLU katmanlarından sonra 2x2'lik en büyük havuzlama işlemi uygulanmıştır. Böylece ağır parametre sayısı ve ağırlık miktarlarını önemli derecede azaltarak CNN modelinin hesaplama maliyetini azaltacak ve ağır ezberlemesine engel olacaktır. En büyük havuzlama katmanından sonra ikinci konvolüsyon katmanında 3x3 filtre 1-adım ve 1-dolgulama işlemleri yapılarak tekrar en fazla bilgi ve öznetelik çıkarımı hedeflenmiştir. İkinci konvolüsyon katmanından sonra tekrar ReLU katmanı sonrasında da ters konvolüsyon katmanı kullanılmıştır. Bu katmanda 4x4 filtre 2-adım ve 1-dolgulama işlemi yapılmıştır. Sonrasında yukarı örnekleme katmanı kullanılmıştır. Ardından 1x1 filtre, 1-adım ve 0-dolgulama işlemi içeren konvolüsyon katmanı ve ardından tekrar yukarı örnekleme katmanı kullanılmıştır. Son olarak sınıflama için softmax aktivasyon işlevi kullanılmış ve çıkış katmanında birleştirme haritası f_{map} görüntüsü elde edilmiştir. Böylece iyi pozlanmış bölge tespiti için CNN modeli kullanarak iyi pozlanmış bölgelerin sınırları tespit edilmiştir. Birleştirilmiş görüntüde meydana gelecek testere etkisini ortadan kaldırmak için, birleştirme haritasındaki (f_{map}) komşu piksel değerleri Eş. 2 kullanılarak ağırlıklı birleşme haritası oluşturulmuş, bu harita üzerinde Eş. 3 hesaplanarak birleştirilmiş görüntüler elde edilmiştir.

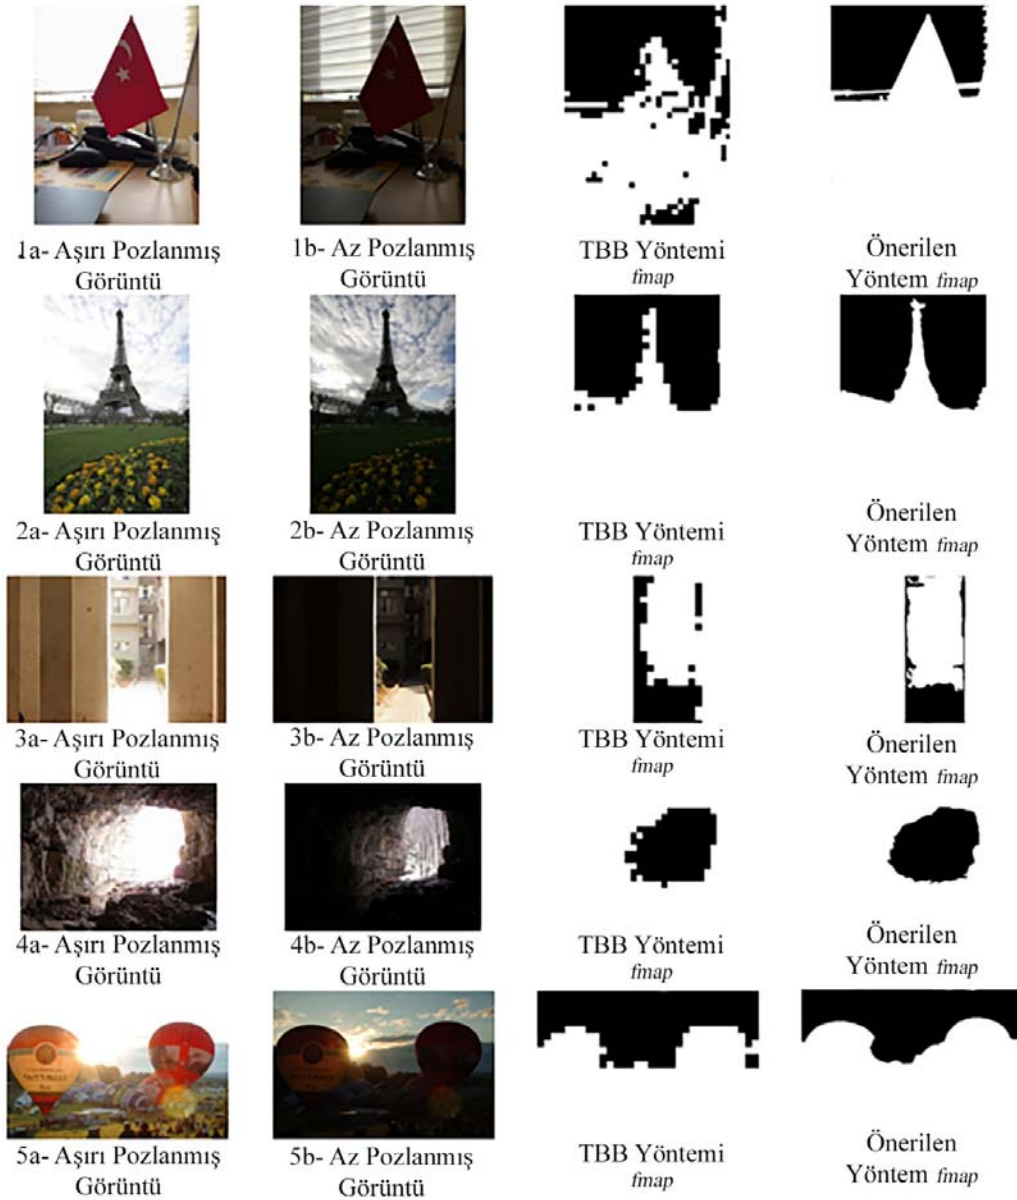


Şekil 9. Önerilen CNN mimarisi (The proposed CNN architecture)

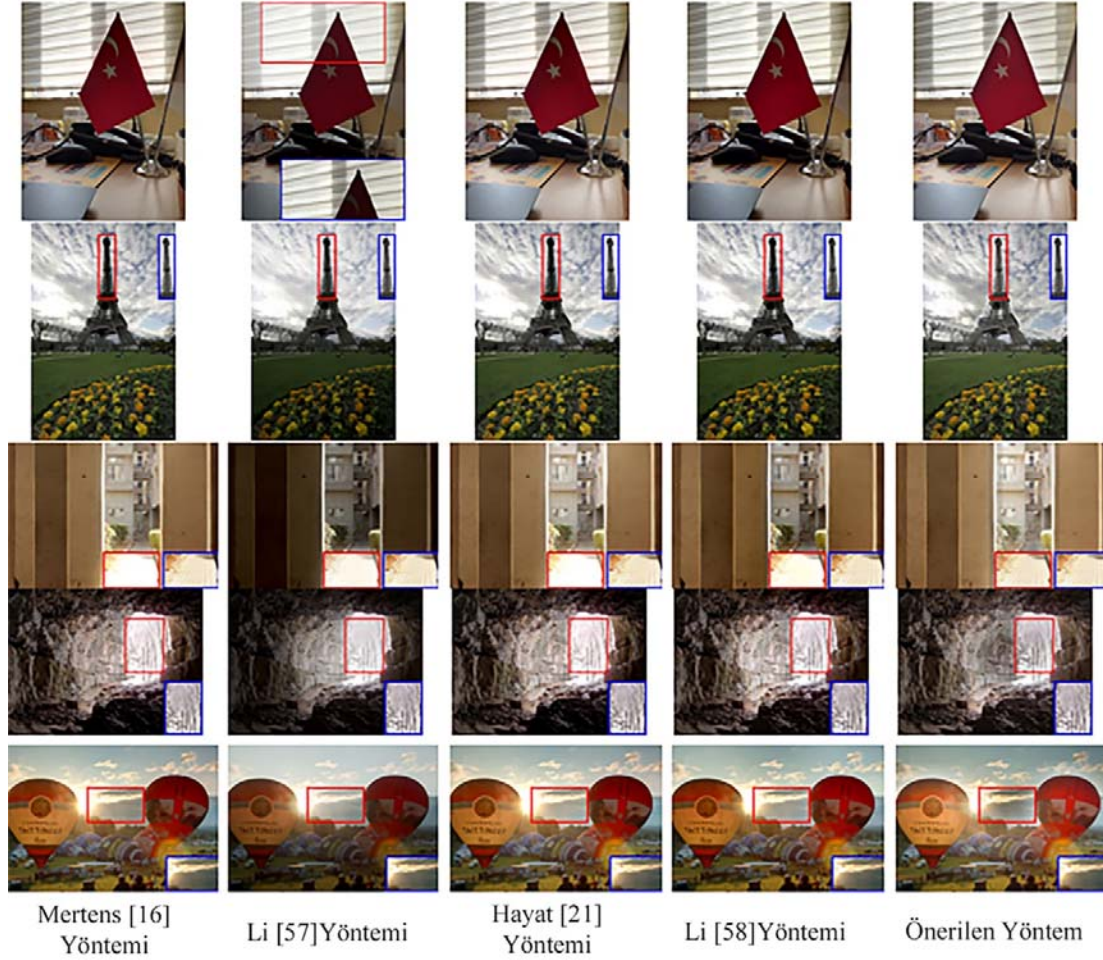
Şekil 10'da bu çalışma kapsamında elde edilen görüntü seti (1) ve literatürde yaygın olarak kullanılan MEF veri setleri (2-5) [51, 57] gösterilmiştir. Her bir görüntü seti için birinci sütunda aşırı pozlanmış kaynak görüntüler gösterilmiştir. Üçüncü sütunda görüntü setlerine Matlab R2018a kullanarak TBB yöntemi ile elde edilen f_{map} görüntüleri, dördüncü sütunda ise önerilen yöntem ile elde edilen f_{map} görüntüleri gösterilmiştir. Şekil 10'dan görüldüğü gibi görüntü seti 1 için, TBB yöntemi iyi pozlanmış kısımların tespitinde gözle görülür hatalar ürettiği görülmüştür. Önerilen yöntemin ise iyi pozlanmış kısımların tespitinde daha iyi sonuç verdiği görülmüştür. Görüntü seti 2 için yine TBB yöntemi problemin doğrusal olmaması nedeniyle iyi sonuç vermediği görülmüştür. Önerilen yöntemin iyi sonuç verdiği görülmüştür. Görüntü seti 3 incelendiğinde önerilen yöntemin diğer

yönteme göre açıkça daha iyi sonuç verdiği görülmüştür. Görüntü seti 4 için TBB yöntemi kötü sonuç verirken önerilen yöntemin daha iyi sonuç verdiği görülmüştür. Görüntü seti 5 için önerilen yöntem çok daha iyi sonuç verirken diğer yöntemin ise iyi sonuç vermediği görülmektedir. Böylelikle önerilen yöntem f_{map} oluşturmada TBB yöntemine göre oldukça başarılı bir performans gösterdiği söylenebilir.

Şekil 11'de literatürde önerilen MEF yöntemlerinden Mertens [16], Li vd. [57], Hayat vd. [21] ve Li vd. [58] ile önerilen MEF yöntemi ile elde edilmiş birleştirilmiş görüntüler karşılaştırılmalı olarak gösterilmiştir. Birleştirilmiş görüntüler, Tablo 1'de erişim adresleri verilen Matlab kodları kullanarak Şekil 10'da gösterilen görüntü setleri üzerine uygulanmış, daha adil bir subjektif kıyaslama



Şekil 10. Geleneksel blok tabanlı ve sunulan MEF yönteminin f_{map} karşılaştırılması.
(f_{map} comparison of TBB and the proposed MEF method.)



Şekil 11. Önerilen ve literatürdeki diğer MEF yöntemlerle elde edilen birleşik görüntülerin karşılaştırılması.
(Comparison of the obtained fused images with the other proposed MEF methods in the literature.)

Tablo 1. Karşılaştırma yapılan MEF yöntemleri ve Matlab programı kodları erişim adresleri
(Compared MEF methods and Matlab program codes access addresses)

Yöntem	Erişim Adresi	Erişim Tarihleri
[16]	https://github.com/Mericam/exposure-fusion	11.04.2022
[53]	https://github.com/xiaohuiben/MEF-CNN-feature	11.04.2022
[21]	https://github.com/ImranNust/Source-Code	11.04.2022
[54]	https://github.com/xiaohuiben/fmmef-TIP-2020	11.04.2022

yapılabilmesi adına mavi çerçeve ile belirtilen kaynak görüntüler eklenerek Şekil 11 elde edilmiştir. Şekil 11'in subjektif değerlendirme sonucunda, görüntü seti 1 için ikinci yöntemin, kırmızı ile işaretli kısımda kaynak görüntüden daha aydınlık yapay görüntü elde ettiği görülmektedir. Diğer yöntemlerin ise birbirlerine yakın sonuçlar elde ettiği görülmektedir. Görüntü seti 2 için önerilen yöntemde işaretli kısmın diğer yöntemlere göre kaynak görüntüye daha yakın bir görüntü elde ettiği görülmektedir. Görüntü seti 3 için ikinci yöntemin yapay parlaklık ürettiği açıkça görülmektedir. Ayrıca önerilen yöntemin işaretli kısmı diğer yöntemlere göre daha iyi bir şekilde birleştirildiği görülmektedir. Görüntü seti 4 için önerilen yöntemin kırmızı ile belirtilen kısmı diğer yöntemlerden daha iyi birleştirildiği görülmektedir. Kırmızı ile belirtilen kısmın sol tarafı ise kaynak görüntülerin pozlanma değerlerinin farkının fazla olmasından dolayı tüm yöntemlerde yapay bir görüntü oluşmuştur. Görüntü seti 5 için ikinci yöntemin yapay bir parlaklık oluşturduğu görülürken diğer yöntemlerin iyi sonuç elde ettiği görülmektedir. Önerilen yöntemde

çerçeve ile belirtilen kısmı diğer yöntemlerden daha iyi birleştirdiği görülürken kaynak görüntüler arasındaki pozlanmışlık farkından dolayı yapaylık oluştuğu görülmektedir.

Tablo 2'de önerilen yöntem ve diğer MEF yöntemlerinin karşılaştırmalı olarak kalite metrik sayısal sonuçları verilmiştir. Tablo 2'nin ilk sütunu kalite metriklerini ifade etmektedir. 2-5. sütunlar ise literatürde sunulan ve önerilen MEF yönteminin kalite metrik sonuçlarını ifade etmektedir. Tablo 2'de belirtildiği gibi; görüntü seti 1, 4 ve 5 için en iyi QM sonuçlarını önerilen yöntem vermiştir. Görüntü seti 2 ve 3 için $QMSML$ değeri olarak Li vd. [58] en iyi sonucu verirken diğer QM değerlerinde ise en iyi sonuçları önerilen yöntem vermiştir. Böylece önerilen MEF yönteminin genel olarak literatürdeki bazı MEF yöntemlerinden QM sayısal değerleri bazında daha iyi sonuçlar verdiği söylenebilir. Tablo 3'te önerilen ve literatürde sunulan diğer bazı yöntemlerin ortalama çalışma zamanı değerleri karşılaştırmalı olarak verilmiştir. Tablonun birinci

Tablo 2. Önerilen ve literatürdeki diğer bazı MEF yöntemleri kalite metrikleri değerlerinin sayısal sonuçlarının karşılaştırılması. (Comparison of the numerical results of the quality metrics values of the proposed and the other MEF methods in the literature.)

Metrik	Mertens [16]	Li [57]	Hayat. [21]	Li vd. [58]	Önerilen Yöntem
Görüntü Seti 1					
Q _{ME}	7,7871	7,7711	7,8598	7,7714	7,8797
Q _{MSML}	11,8297	8,3764	11,8445	12,0002	12,1981
Q _{MCB}	0,6005	0,5194	0,6164	0,6061	0,6519
Q _{MSSIM}	0,8225	0,8465	0,8254	0,8231	0,8492
Görüntü Seti 2					
Q _{ME}	7,7311	7,4479	7,7062	7,6614	7,7987
Q _{MSML}	21,9574	16,6940	22,0091	22,4206	22,3559
Q _{MCB}	0,7035	0,5972	0,6996	0,7078	0,7344
Q _{MSSIM}	0,8310	0,8601	0,8304	0,8308	0,8656
Görüntü Seti 3					
Q _{ME}	7,3273	6,9086	7,4421	7,4150	7,6264
Q _{MSML}	12,2924	9,3800	12,0351	13,2437	12,5048
Q _{MCB}	0,4656	0,4622	0,4699	0,5025	0,5432
Q _{MSSIM}	0,8183	0,8310	0,8178	0,8130	0,8413
Görüntü Seti 4					
Q _{ME}	7,1565	7,2425	7,2410	7,5603	7,6049
Q _{MSML}	37,0586	24,0542	36,5430	38,3217	39,1433
Q _{MCB}	0,5120	0,4823	0,5082	0,5218	0,5372
Q _{MSSIM}	0,8153	0,8381	0,8159	0,8151	0,8472
Görüntü Seti 5					
Q _{ME}	7,7720	7,5538	7,7783	7,7243	7,7907
Q _{MSML}	12,4731	7,9501	12,2742	12,7664	12,8269
Q _{MCB}	0,6035	0,5425	0,5996	0,6229	0,6305
Q _{MSSIM}	0,8194	0,8448	0,8195	0,8176	0,8516

Tablo 3. Önerilen ve literatürdeki diğer bazı MEF yöntemleri ortalama çalışma zamanı değerlerinin sayısal sonuçlarının karşılaştırılması

(Comparison of the numerical results of the average running time values of the proposed and the other MEF methods in the literature)

Veri Seti	Ortalama Çalışma Zamanı (s)				
	Mertens [16]	Li [57]	Hayat. [21]	Li vd. [58]	Önerilen Yöntem
Görüntü Seti 1	1,5646	1,5735	2,5230	2,2215	1,3315
Görüntü Seti 2	0,9555	0,9642	1,5725	1,4432	0,9327
Görüntü Seti 3	1,0262	1,1234	1,6197	1,4186	0,8560
Görüntü Seti 4	1,0455	1,2420	1,6637	1,4436	0,9597
Görüntü Seti 5	0,9435	0,9649	1,5030	1,3517	0,9403

sütununda veri setleri, iki ila dördüncü sütunda literatürde sunulan diğer MEF yöntemlerinin ortalama çalışma süreleri, son sütunda ise önerilen yöntemin ortalama çalışma süreleri verilmiştir. Tablo 3'ten anlaşılacağı üzere tüm veri setlerinde ortalama çalışma değerlendirilmesinde en iyi sonucu önerilen yöntemin verdiği söylenebilir.

Sonuç olarak görüntü birleştirmede kullanılan kalite metrik sayısal sonuçları ve ortalama çalışma zamanı değerlendirildiğinde önerilen yöntemin daha iyi sonuçlar verdiği söylenebilir. Böylece önerilen yöntemin özellikle birleştirilmiş görüntüye hızlıca ulaşılma istenildiğinde tercih edilmesi önerilmektedir. Sübjektif değerlendirme kişiden kişiye değişiklik arz edeceğinden dolayı sübjektif değerlendirme olarak da tatmin edici sonuçlar verdiği söylenebilir.

Sonuçlar (Conclusions)

Bu çalışmada DL modellerinden çok boyutlu ve doğrusal olmayan problem çözümünde etkili sonuç veren CNN modeli kullanarak iyi pozlanmış bölge temelli MEF için yeni bir yöntem önerilmiştir. Bölge temelli MEF yöntemlerinde en önemli problem, iyi pozlanmış bölgelerin tespit edilmesidir. Önerilen yöntemde ilk olarak kaynak görüntüler CNN modeli kullanılarak f_{map} haritası oluşturulmuştur.

Yeni bir CNN modeli geliştirmek uzun ve zorlu bir süreç olduğundan ön eğitilmiş SegNet temelli CNN modeli kullanılmıştır. Ağın mimarisini konvolüsyon katmanı, ReLU aktivasyon işlevi, havuzlama katmanı, ters konvolüsyon katmanı, piksel tabanlı sınıflama yapmak için softmax aktivasyon işlevi ve son olarak da çıkış katmanından oluşturulmuştur. Birleştirme haritası elde edildikten sonra, kaynak görüntüler doğrudan birleştirildiğinde birleştirilmiş görüntüde testere-dişi etkisi göstermemesi için ağırlıklı olarak birleştirilerek her tarafı iyi pozlanmış birleştirilmiş görüntü elde edilmiştir. Önerilen yöntem literatürde yaygın olarak kullanılan MEF veri setleri ve bizim elde ettiğimiz veri seti için uygulanmıştır. Elde edilen birleştirilmiş görüntüler Q_{ME} , Q_{MSML} , Q_{MCB} ve Q_{MSSIM} kalite metrikleri kullanarak değerlendirilmiştir. Önerilen yöntemin ortalama çalışma zamanı diğer MEF yöntemleri ile karşılaştırılmıştır. Önerilen yöntemin hem sayısal sonuçlar hem de görsel değerlendirme sonuçları neticesinde geleneksel blok tabanlı ve literatürde sunulan bazı MEF yöntemlerinden daha iyi sonuçlar verdiği görülmüştür. Önerilen yöntemde sadece iki kaynak görüntü girişi kullanılmıştır. Bundan sonraki çalışmalar için yöntem ikiden fazla kaynak görüntü girişi için düzenlenebilir. Kullanılan CNN modelinde parametre ayarlaması yapılarak elde edilen sonuçlar geliştirilebilir. Testere-dişi etkisini ortadan kaldırmak için kılavuzlu filtre kullanılabilir ve sonuçlar değerlendirilebilir.

Kaynaklar (References)

1. Kaur H., Koundal D., Kadyan V., Image fusion techniques: A Survey, *Arch Computat Methods Eng*, 28, 4425–4447, 2021.
2. Karishma C.B., Bhumika S., A review of image fusion techniques, 2018 Second International Conference on Computing Methodologies and Communication (ICCMC), 2018.
3. Ma J., Ma Y., Li C., Infrared and visible image fusion methods and applications: A survey, *Information Fusion*, 45, 153-178, 2019.
4. Aslantas V., Bendes E., Kurban R., Toprak, A.N., New optimised region-based multi-scale image fusion method for thermal and visible images, *IET Image Processing*, 289-299, 2014.
5. Maruthi R., Lakshmi I., Multi-focus image fusion methods – A Survey, *IOSR Journal of Computer Engineering (IOSR-JCE)*, 19 (4), 9-25, 2017.
6. Aslantas V., Kurban R., Fusion of multi-focus images using differential evolution algorithm, *Expert Systems with Applications*, 8861–8870, 2010.
7. Aslantaş V., Kurban R., A comparison of criterion functions for fusion of multi-focus noisy images, *Optics Communications*, 16 (282), 3231–3242, 2009.
8. Aslantas V., Bendes E., A new image quality metric for image fusion: The sum of the correlations of differences, *Int. J. Electron. Commun.*, 69, 1890-1896, 2015.
9. Wei H., Zhongliang J., Evaluation of focus measures in multi-focus image fusion, *Pattern Recognition Letters*, 28 (4), 493-500, 2007.
10. Ke P., Jung C., Fang Y., Perceptual multi-exposure image fusion with overall image quality index and local saturation, *Multimedia Systems*, 23 (2), 239–250, 2017.
11. Singh S., Mittal N., Singh H., Review of various image fusion algorithms and image fusion performance metric, *Archives of Computational Methods in Engineering*, 28 (5), 3645–3659, 2021.
12. Zhao S., Wang Y., A Novel patch-based multi-exposure image fusion using super-pixel segmentation, *IEEE Access*, 8, 39034-39045, 2020.
13. Yadong X., Beibei S., Color-compensated multi-scale exposure fusion based on physical features, *Optik*, 223, 2020.
14. Bavirisetti D.P., Dhuli R., Multi-focus image fusion using multi-scale image decomposition and saliency detection, *Ain Shams Engineering Journal*, 9, 1103–1117, 2018.
15. Zhang X., Benchmarking and comparing multi-exposure image fusion algorithms, *Information Fusion*, 74, 111-131, 2021.
16. Mertens T., Kautz J., Reeth F.V., Exposure Fusion, 15th Pacific Conference on Computer Graphics and Applications, USA, 2007.
17. Malik M.H., Gilani S.A.M., Anwaar-ul-Haq, Wavelet based exposure fusion, *Proceedings of the World Congress on Engineering*, London, 2008.
18. Wang J., Xu D., Lang C., Li B., Exposure fusion based on shift-invariant discrete wavelet transform, *Journal Of Information Science And Engineering*, 27, 197-211, 2011.
19. Martorell O., Sbert C., Buades A., Ghosting-free DCT based multi-exposure image fusion, *Signal Processing: Image Communication*, 78, 409-425, 2019.
20. Kou F., Zhengguo L., Changyun W., Weihai C., Edge-preserving smoothing pyramid based multi-scale exposure fusion, *J. Vis. Commun. Image Represent*, 53, 235–244, 2018.
21. Hayat N., Imran M., Ghost-free multi exposure image fusion technique using dense SIFT descriptor and guided filter, *Journal of Visual Communication and Image Representation*, 62, 295-308, 2019.
22. Qiegen L., Leung H., Variable augmented neural network for decolorization and multi-exposure fusion, *Information Fusion*, 46, 114-127, 2019.
23. Song M., Tao D., Chen C., Bu J., Luo J., Zhang C., Probabilistic exposure fusion, *IEEE Trans. Image Process*, 21 (1), 341-357, 2012.
24. Gu B., Li W., Wong J., Zhu M., Wang M., Gradient field multi-exposure images fusion for high dynamic range image visualization, *J. Vis. Commun. Image Represent*, 23 (4), 604-610, 2012.
25. Li S., Kang X., Fast multi-exposure image fusion with median filter and recursive filter, *IEEE Trans. Consum. Electron*, 58 (2), 626-632, 2012.
26. Bo G., Wujing L., Jiangtao W., Minyun Z., Minghui W., Gradient field multi-exposure images fusion for high dynamic range image visualization, *Journal of Visual Communication and Image Representation*, 23 (4), 604-610, 2012.
27. Zhang W., Cham W., Gradient-directed multiexposure composition, *IEEE Transactions on Image Processing*, 21 (4), 2318-2323, 2012.
28. Sujoy P., Ioana S.S., Panajotis A., Multi-exposure and multi-focus image fusion in gradient domain, *Journal of Circuits, Systems and Computers*, 25 (10), 1650123, 2016.
29. Goshtasby A.A., Fusion of multi-exposure images, *Image and Vision Computing*, 23 (6), 611–618, 2005.
30. Kong J., Wang R., Lu Y., Feng X., Zhang J., A Novel fusion approach of multi-exposure image, *EUROCON 2007 The International Conference on “Computer as a Tool”*, Warsaw-Poland, 2007.
31. Kede M., Hui L., Hongwei Y., Zhou W., Deyu M., Lei Z., Robust multi-exposure image fusion: A structural patch decomposition approach, *IEEE Trans. Image Processing*, 26 (5), 2519–2532, 2017.
32. Zhang W., Hu S., Liu K., Patch-based correlation for deghosting in exposure fusion, *Information Sciences*, 415–416, 19-27, 2017.
33. Zhang W., Hu S., Liu K., Yao J., Motion-free exposure fusion based on inter-consistency and intra-consistency, *Information Sciences*, 376, 190-201, 2017.
34. Ma K., Duanmu Z., Zhu H., Fang Y., Wang Z., Deep guided learning for fast multi-exposure image fusion, *IEEE Transactions on Image Processing*, 29, 2808-2819, 2020.
35. Xu H., Ma J., Zhang X., MEF-GAN: Multi-exposure image fusion via generative adversarial networks, *IEEE Transactions on Image Processing*, 29, 7203-7216, 2020.
36. Prabhakar K.R., Srikar V.S., Babu R.V., A Deep unsupervised approach for exposure fusion with extreme exposure image pairs, *International Conference on Computer Vision (ICCV)*, 2017.
37. Qi Y., Zhou S., Zhang Z., Luo S., Lin X., Wang L., Qiang B., Deep unsupervised learning based on color un-referenced loss functions for multi-exposure image fusion, *Information Fusion*, 66, 18-39, 2021.
38. Somuncu E., Aydın Atasoy N., Realization of character recognition application on text images by convolutional neural network, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (1), 17-28, 2021.
39. Elmas B., Identifying species of trees through bark images by convolutional neural networks with transfer learning method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (3), 1253-1270, 2021.
40. Elmas B., Classification varieties of marble and granite by convolutional neural networks with transfer learning method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (2), 985-1002, 2022.
41. Narin A., İşler Y., Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (4), 2095-2108, 2021.
42. Romanuke V.V., An infinitely scalable dataset of single-polygon grayscale images as a fast test platform for semantic image segmentation, *KPI Science News*, 1, 24-34, 2019.
43. Alzubaidi L., Zhang J., Humaidi A.J., Al-Dujaili A., Duan Y., Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, *Journal of Big Data*, 8 (53), 2021.
44. Krizhevsky A., Sutskever I., Hinton G.E., Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 1097–1105, 2012.
45. Simonyan K., Zisserman A., Very deep convolutional networks for large-scale image recognition, 3rd International Conference on Learning Representations (ICLR), San Diego-CA-USA, 2015.
46. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., Going deeper with convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015.
47. He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, 2016.
48. Badrinarayanan V., Kendall A., Cipolla R., SegNet: A deep convolutional encoder-decoder architecture for image segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39 (12), 2481-2495, 2017.
49. Minaee S., Boykov Y.Y., Porikli F., Plaza, A.J., Kehtarnavaz N., Terzopoulos D., Image segmentation using deep learning: A Survey, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021.
50. Paoletti M.E., Haut J.M., Plaza J., Plaza A., Deep learning classifiers for hyperspectral imaging: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 279-317, 2019.

51. Ma K., Zeng K., Wang Z., Perceptual quality assessment for multi-exposure image fusion, *IEEE Transactions on Image Processing*, 24 (11), 3345-3356, 2015.
52. Jagalingam P., Hegde A.V., A review of quality metrics for fused image, *Aquatic Procedia*, 133-142, 2015.
53. Nayar S.K., Nakagawa Y., Shape from focus, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16 (8), 824–831, 1994.
54. Chen Y., Blum, R.S., A new automated quality assessment algorithm for image fusion, *Image and Vision Computing*, 1421-1432, 2009.
55. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P., Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*, 13 (4), 600-612, 2004.
56. Hasan M., Sohel F., Diepeveen D., Laga H., Jones M.G.K., A survey of deep learning techniques for weed detection from images, *Computers and Electronics in Agriculture*, 184, 2021.
57. Li H., Zhang L., Multi-exposure fusion with CNN features, 25th IEEE International Conference on Image Processing (ICIP), Athens-Greece, 2018.
58. Li H., Ma K., Yong H., Zhang L., Fast multi-scale structural patch decomposition for multi-exposure image fusion, *IEEE Trans. Image Process*, 29, 5805–5816, 2020.

