



A new hybrid approach for multi-focus image fusion using CNN and SVM methods

Samet Aymaz*

Turkey Ministry of Health, Department of Health Information Systems, Trabzon, 61000, Türkiye

Highlights:

- Automatic feature extraction with the originally designed CNN architecture.
- Hybrid use of CNN and SVM methods.
- An effective fusion approach that can easily work even in simple systems

Keywords:

- CNN
- SVM
- Feature extraction
- Fusion rules
- Gradient

Article Info:

Research Article
Received: 21.11.2022
Accepted: 11.06.2023

DOI:

10.17341/gazimmfd.1208107

Correspondence:

Author: Samet Aymaz
e-mail:
samet.aymaz@saglik.gov.tr
phone: +90 530 136 1197

Graphical/Tabular Abstract

Multi-focus image fusion creates a detailed all-focus image by combining two or more images with different focus values belonging to the same scene. In the proposed study, a new hybrid approach for multi-focus image fusion is proposed. In this study, while using the automatic feature extraction of the CNN structure, the successful classification structure of the SVM classifier is used. The flow of the proposed study is given in Figure A.

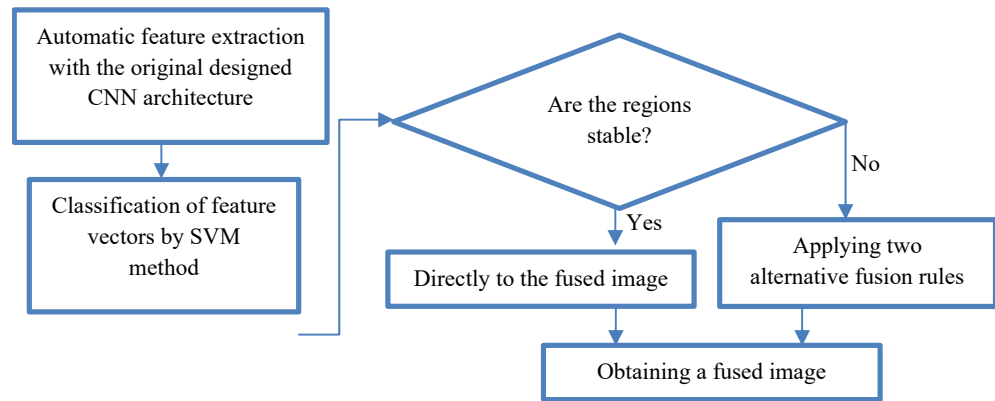


Figure A. Flow diagram for proposed approach

Purpose:

The proposed study aims to create a hybrid classification method including CNN and SVM approaches and a valuable tool for multi-focus image fusion with effective fusion rules.

Theory and Methods:

This study proposes a multi-focus image fusion approach that classifies image patches as focused and unfocused. First, the crucial features of the image patches in the source images are extracted with the originally designed Convolutional Neural Network (CNN) architecture. The extracted features are given to the Support Vector Machine (SVM) classifier, and the class of the related feature vector is determined. Thus, binary decision maps are created for each source image. In addition to these decision maps, cases in which the classifiers stay unstable in the proposed study (giving the same class label for the corresponding image patches in the source images) are also kept in a matrix. While the stable regions are transferred directly to the fused image, two different fusion rules are applied for the unstable regions, Gradient-based and Laplace-based. The application of two different fusion rules is carried out to observe the effect of the fusion rule on fusion. After the fusion operations, a new image is created with all the details. The performance of the proposed study is measured by objective assessments using this image.

Results:

In the proposed study, performance measurements are made using the Lytro data set [23] and the data set prepared by Durga Prasad [24]. When the results are examined, it is seen that the proposed study is superior to studies in the literature.

Conclusion:

Multi-focus image fusion methods aim to extract correct focus information from the source images to fused images and to preserve the detailed information in the source images for fused images. The approach prepared for this purpose and having original designs is expected to be a preliminary assistant for multi-focus image fusion without the need for expensive hardware.



CNN ve SVM yöntemleriyle çoklu-odaklı görüntü birleştirmede yeni bir hibrit yaklaşım

Samet Aymaz*

T.C. Sağlık Bakanlığı, Sağlık Bilgi Sistemleri Daire Başkanlığı, Trabzon, 61000, Türkiye

ÖNEÇIKANLAR

- Tasarlanan özgün CNN mimarisi ile otomatik özellik çıkarımı
- CNN ve SVM yöntemlerinin hibrit olarak kullanılması
- Basit sistemlerde bile kolaylıkla çalışabilecek etkili bir füzyon yaklaşımı

Makale Bilgileri

Araştırma Makalesi

Geliş: 21.11.2022

Kabul: 11.06.2023

DOI:

10.17341/gazimmfd.1208107

Anahtar Kelimeler:

CNN,
SVM,
özellik çıkarımı,
füzyon kuralı,
gradyan

ÖZ

Çoklu-odaklı görüntü birleştirme, aynı sahnenin farklı odak değerlerine sahip iki veya daha fazla görüntüsünün birleştirilerek tüm-odaklı bir görüntü oluşturulmasıdır. Tüm-odaklı görüntü oluşturulurken temel amaç kaynak görüntülerdeki doğru odak bilgisinin maksimum seviyede birleştirilmiş görüntüye aktarılmasıdır. Önerilen çalışmada, bu amaç doğrultusunda yeni bir hibrit yaklaşım önerilmektedir. Bu yaklaşım, görüntülerden çıkarılan önemli özelliklerin sınıflandırılması ve etkili füzyon kuralları ile birleştirilmesine dayanmaktadır. Özellik çıkarımında, özgün olarak tasarlanan ve basit sistemlerde dahi kolaylıkla çalışabilen bir CNN mimarisi kullanılmaktadır. Çıkarılan özellikler, SVM sınıflandırıcısına verilmekte ve özellik vektörünün odaklı ya da odaksız olarak sınıflandırılması sağlanmaktadır. Sınıflandırma işlemleri sonrasında her bir kaynak görüntü için ikili karar haritaları oluşturulmaktadır. Bu karar haritalarının yanında, önerilen çalışmanın özgün yönlerinden birisi de kararsız bölgelere ait haritaların da çıkarılmasıdır. Bu bölgeler, sınıflandırıcının özellik vektörlerini tam olarak sınıflandıramadığı odaklı bölgelerden odaksız bölgelere geçiş noktalarından oluşmaktadır. Görüntü birleştirmede en önemli konulardan birisi de füzyon kuralının seçimidir. Önerilen çalışmada, sınıflandırıcının kesin olarak karar verebildiği noktalar doğrudan birleştirilmiş görüntüye aktarılırken, kararsız bölgeler için iki alternatif füzyon kuralı kullanılmaktadır. Bunlar gradyan-tabanlı ve laplas-tabanlı füzyon kurallarıdır. Çalışmada her bir füzyon kuralı için, füzyon kurallarının birleştirmeye etkisi gözlemlenmektedir. Sonuç olarak, önerilen çalışmanın performansı objektif performans metrikleriyle değerlendirilmektedir. Sonuçlar incelendiğinde, çalışmanın basit sistemlerde çalışabilen etkili bir füzyon aracı olduğu görülmektedir.

A new hybrid approach for multi-focus image fusion using CNN and SVM methods

HIGHLIGHTS

- Automatic feature extraction with the originally designed CNN architecture
- Hybrid use of CNN and SVM methods
- An effective fusion approach that can easily work even in simple systems

Article Info

Research Article

Received: 21.11.2022

Accepted: 11.06.2023

DOI:

10.17341/gazimmfd.1208107

Keywords:

CNN,
SVM,
feature extraction,
fusion rule,
gradient

ABSTRACT

Multi-focus image fusion creates a new all-focus image by combining two or more images of the same scene with different focus values. When creating an all-focus image, the primary purpose is to transfer the correct focus information from the source images to the fused image at the maximum level. The proposed study implements a new hybrid approach for this purpose. This approach is based on classifying notable features extracted from images and combining them with effective fusion rules. In feature extraction, a CNN architecture is used, which is originally designed and can efficiently work even in simple systems. The extracted features are given to the SVM classifier, and the feature vector classification as focused or unfocused is provided. After the classification processes, binary decision maps are created for each source image. In addition to these decision maps, one of the unique aspects of the proposed study is the extraction of maps of unstable regions. These regions consist of transition points from focused to unfocused regions, where the classifier cannot fully classify the feature vectors. One of the most critical issues in image fusion is the choice of fusion rule. In the proposed study, the points the classifier can decide with certainty are transferred directly to the fused image, while two alternative fusion rules are used for unstable regions. These are Gradient-based and Laplace-based fusion rules. The effect of fusion rules on fusion is seen by the fusion of source images separately for each fusion rule. As a result, the performance of the proposed study is evaluated with objective performance metrics. When the results are examined, it is seen that the study is an effective fusion tool that can work in simple systems.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *samet.aymaz@saglik.gov.tr / Tel: +90 530 136 1197

1. Giriş (Introduction)

Çoklu-odaklı görüntü birleştirme, aynı sahneye ait iki ya da daha fazla farklı odak değerine sahip görüntünün birleştirilerek tüm-odaklı görüntü oluşturulmasıdır. Odak problem, görüntüleme cihazlarındaki optik lenslerin sınırlı derinliklerdeki nesnelere odaklanabilmesinden kaynaklanmaktadır [1]. Görüntülerde yakın mesafedeki nesnelere odaklı olurken uzak mesafede bulunan nesnelere odak dışı kalmaktadır. Bu probleme odaklanan çoklu-odaklı görüntü birleştirme yöntemleri, mikro-görüntü birleştirme [2], sensör ağırları [3], güç devresi denetimi [4] vb. gibi alanlarda da tercih edilmektedir.

Çoklu-odaklı görüntü birleştirme yöntemleri son yıllarda görüntüleme cihazlarının artmasıyla çok daha önemli bir yere sahip olmaktadır. Bu yöntemler, temel olarak iki sınıfta incelenmektedir. Dönüşüm-tabanlı yöntemler ve uzamsal-tabanlı yöntemler [5, 6]. Son yıllarda, derin öğrenme yöntemleri diğer alanlarda olduğu gibi bu alanda da popüler hale geldi. Bu nedenle, derin öğrenmeye dayalı yaklaşımlar bu alanda üçüncü sınıf olarak yerini aldı.

Dönüşüm-tabanlı yöntemler, görüntülerin frekans bileşenlerinden faydalanarak birleştirme yapmayı amaçlamaktadır. Bu yöntemler temel olarak, üç farklı aşamadan oluşmaktadır. İlk olarak, kaynak görüntüler farklı dönüşümler kullanılarak frekans bileşenlerine ayrılır. Daha sonra, bu frekans bileşenleri uygun birleştirme kuralları ile birleştirilir. Sonuç olarak, frekans bileşenleri ters dönüşüm ile tüm-odaklı tek bir görüntüye dönüştürülür. Bu yöntemlerin avantajı, görüntülerin farklı frekans bileşenleri kullanılarak detaylı bir analize izin vermesidir. Literatürde, çok-ölçekli yöntemler [7], gradyan-alanı yöntemleri [8], seyrek-temsil yöntemi [9] ve hibrit metotlar [10] gibi dönüşüm alanına dayalı yaklaşımlar bulunmaktadır.

Uzamsal-tabanlı yöntemler, kaynak görüntülerin piksel parlaklık değerlerinden yola çıkarak görüntü birleştirme yapmaktadır. Bu yaklaşımlar, dönüşüm-tabanlı yaklaşımlara göre daha az tercih edilmektedir. Çünkü, görüntülerdeki piksel parlaklık değerleri odak değerlerini bulmak için yeterli olmamaktadır. Bu tür yöntemler, piksel-tabanlı [11], blok-tabanlı [12] ve alan-tabanlı [13] olmak üzere 3 gruba ayrılmaktadır. Tüm bu yaklaşımlar, doğrudan piksel parlaklık değerlerini kullanmaktadır.

Derin öğrenmeye dayalı yöntemler, son yıllarda her alanda olduğu gibi bu alanda da popüler hale gelmiştir. Bu yaklaşımların, görüntüler üzerinde baskın özellikleri otomatik olarak çıkarabilmesi çoklu-odaklı görüntü birleştirme için oldukça önemlidir. Literatürde, farklı derin öğrenme yöntemleri kullanılmaktadır. İlk olarak, Liu vd. [14], derin öğrenme yöntemini görüntü birleştirme amacına uygun olarak kullanmıştır. Bu çalışmada, Evrişimli Sinin Ağları (CNN) mimarisine dayanan bir görüntü birleştirme yapılmıştır. Derin öğrenmeye dayalı yaklaşımlar, bu çalışma sonrasında giderek yaygınlaşmıştır. Literatürde, önerilen yaklaşımlar genellikle kaynak görüntülerin odaklı veya odaksız olarak sınıflandırılmasına dayanmaktadır. Tang vd. [15], kaynak görüntülerden çıkarılan yamaların odaklı veya odaksız olarak sınıflandırılmasına dayanan CNN mimarisine tabanlı bir yaklaşım önermiştir. Bu yaklaşım ile başarılı bir birleştirme yapmaktadırlar. Amin-naji vd. [16] ve Ma vd. [17] ise sınıflandırma doğruluğunu ensemble öğrenme tekniği ile artırarak çoklu-odaklı görüntü birleştirme alanına katkı yapmışlardır. Yan vd. [18] ise CNN mimarisine Yapısal Benzerlik İndeksi (SSIM) kayıp fonksiyonu uygulayarak odaklı ve odaksız bölgeleri birbirinden ayırabilecek bir yaklaşım oluşturmuşlardır. Jung vd. [19], gradyan-tabanlı bir kayıp fonksiyonu içeren bir ağ tasarlamış ve başarılı bir birleştirme yapmışlardır. Bu yaklaşımların yanında literatürde farklı yaklaşımlar [20, 21] da önerilmekte ve bu yaklaşımların sayısı artarak devam etmektedir.

Bu çalışmada, çoklu-odaklı görüntü birleştirme için yeni bir hibrit yaklaşım önerilmektedir. Bu yaklaşım, kaynak görüntülerin odaklı veya odaksız olarak sınıflandırılmasına dayanmaktadır. Sınıflandırma işlemi için ilk olarak zengin bir eğitim seti hazırlanmaktadır. Daha sonra, tasarlanan özgün CNN mimarisini ile bu mimarinin literatürdeki kullanımının aksine görüntülerin önemli özellikleri otomatik olarak çıkarılmaktadır. Bu özellik vektörleri, optimum parametreleri Grid Arama yaklaşımı ile bulunan Destek Vektör Makineleri (SVM) sınıflandırıcılara giriş olarak verilmekte ve odaklı veya odaksız olarak sınıflandırılmaktadır. Bu işlem her bir kaynak görüntü için yapılmakta ve karar haritaları oluşturulmaktadır. Özellikle, kaynak görüntülerde odaklı bölgelerden odaksız bölgelere geçişte sınıflandırıcılar genellikle hatalı sonuçlar (her bir görüntü yamasının odaklı olarak etiketlenmesi) vermekte ve kararsız kalmaktadır. Bu bölgeler kararsız bölge olarak adlandırılmaktadır. Önerilen yaklaşım, literatürdeki yöntemlerin aksine etkili iki farklı füzyon kuralı olarak birleştirilmektedir. Bu kurallar gradyan-tabanlı füzyon kuralı ve laplas-tabanlı füzyon kuralıdır. Kararlı bölgeler doğrudan birleştirilmiş görüntüye aktarılırken kararsız bölgeler bu füzyon kuralları ile aktarılmaktadır. Sonuç olarak tüm-odaklı birleştirilmiş görüntüler oluşturulmaktadır. Önerilen yaklaşımın özgün yanları maddeler halinde aşağıda belirtilmektedir.

- Zengin bir eğitim veri seti oluşturulması.
- Tasarlanan özgün CNN mimarisini ile otomatik özellik çıkarımı.
- CNN ve SVM yöntemlerinin hibrit olarak kullanılması.
- Kararlı ve kararsız bölge tespiti yapılarak, kararsız bölgelerde etkili füzyon kuralları kullanılması.
- Basit sistemlerde bile kolaylıkla çalışabilecek etkili bir füzyon yaklaşımı.
- Grid Arama yöntemi ile optimum parametrelerin belirlenmesi.

2. Teorik Metod (Theoretical Method)

Bu çalışmada, çoklu-odaklı görüntü birleştirme için hibrit bir yaklaşım önerilmektedir. Bu yaklaşım, kaynak görüntülerin odaklı veya odaksız olarak sınıflandırılarak her bir görüntü için karar haritasının oluşturulması ve oluşturulan karar haritalarının birleştirilerek tüm-odaklı bir görüntü elde edilmesini amaçlamaktadır. Sınıflandırmaya dayalı yaklaşımlarda en önemli noktalar zengin bir veri seti oluşturulması ve özellik çıkarımıdır. Bu çalışmada, eğitim veri seti Cifar-100 [22] veri seti kullanılarak özgün olarak oluşturulmuştur. Veri seti oluşturulması bölüm 2.1'de detaylı olarak verilmektedir. Sınıflandırma yöntemleri için görüntülerin hangi özelliklerinin daha önemli olduğunun tespiti oldukça zordur. Özellik çıkarımları genellikle deneme yanılma metodu kullanılarak yapılmaktadır. Bu durum hem vakit kaybına neden olmakta hem de başarılı sınıflandırıcılar elde edilememektedir. Önerilen çalışmada, insan gözetimi olmadan görüntülerin önemli özelliklerini otomatik olarak belirleyebilen özgün bir CNN mimarisini tasarlanmaktadır. Bu mimarinin detayları bölüm 2.2'te verilmektedir. Çıkarılan özellikler, SVM sınıflandırıcı modelinin oluşturulmasında kullanılmaktadır. SVM sınıflandırıcı modeli oluşturulması ve detayları bölüm 2.3'te verilmektedir. Çoklu-odaklı görüntü birleştirme yöntemlerinde kullanılacak veri seti sayısı sınırlıdır. Lytro veri seti [23] ve Durga Prasad tarafından hazırlanan veri seti [24] bunlar içerisinde en önemlileridir. Lytro veri seti renkli görüntülerden oluşurken, diğer veri seti gri seviye görüntülerden oluşmaktadır. Önerilen çalışmada, her iki veri setinden örnekler de kullanılmaktadır.

Bu veri setlerinden alınan kaynak görüntüler ilk olarak tasarlanan CNN mimarisinin giriş katmanı boyutlarına uygun olarak örtüşen 32x32lik bloklara ayrılır. Daha sonra her bir blok ayrı ayrı CNN mimarisine beslenerek her bir bloğa ait özellikler çıkarılır ve bu özellikler eğitilmiş SVM modeline giriş olarak verilir. CNN yaklaşımı

hem özellik çıkarımında hem de sınıflandırma için başarılı bir yaklaşımdır. Fakat CNN yaklaşımının yavaş olması ve bellek gereksinimi çok fazla olması nedeniyle sınıflandırma için bu çalışmada tercih edilmemektedir. Bu çalışmada milyonlarca piksel ile çalışmak yerine bu pikselleri en iyi nitelendirebilecek bir özellik vektörü oluşturulması ve bu vektörün basit ve etkili bir sınıflandırma yaklaşımı ile sınıflandırılması amaçlanmaktadır. Böylece CNN mimarisinin etkili özellik çıkarımından faydalanırken aynı zamanda SVM yaklaşımının hızlı ve doğru karar verme özelliklerinden faydalanılmıştır. SVM, sınıflandırıcısı odaklı bölgeler için 1 çıkışı verirken odaksız bölgelerde 0 çıkışı vermektedir. Her bir blok için sınıflandırma işlemi tekrarlanır ve böylece her bir kaynak görüntü için ikili karar görüntüleri oluşturulur. Bu aşamada önerilen çalışma literatürdeki diğer yöntemlerden ayrılmaktadır. Sınıflandırıcılar bazı durumlarda odaklı ve odaksız bölgeleri ayırmakta zorlanır ve her kaynak görüntü için aynı sonucu üretir. Bu durumlar genellikle odaklı bölgelerden odaksız bölgelere geçiş noktalarında ortaya çıkar. Önerilen çalışmada, kararsız bölgeler için farklı bir birleştirme kuralı uygulanır. Kararlı bölgeler doğrudan birleştirilmiş görüntüye aktarılırken, kararsız bölgeler için iki farklı birleştirme kuralı denenmektedir. Bunlar gradyan-tabanlı ve laplas-tabanlı füzyon kurallarıdır. Bu kurallar bölüm 2.4'te detaylı olarak verilir. Kararsız bölgelerin birleştirilmiş görüntüye doğru olarak aktarılması oldukça önemlidir çünkü bu noktalar göz ardı edildiğinde incelenmesi kolay net görüntüler elde edilemeyecektir. Birleştirme işlemlerinden sonra tüm-odaklı tek bir görüntü oluşturulur ve yöntemin performansı objektif ölçüm metrikleri yardımıyla değerlendirilir. Önerilen çalışmaya ait akış diyagramı Şekil 1 ile verilmektedir.

2.1. Eğitim veri seti oluşturulması (Creating training data set)

Önerilen çalışmada, odaklı ve odaksız bölgelerin sınıflandırılmasına dayanan bir yaklaşım önerilmektedir. Sınıflandırma işlemi için zengin bir eğitim veri kümesine ihtiyaç duyulmaktadır. Eğitim veri seti odaklı ve odaksız görüntü yamalarından oluşmaktadır. Bu veri seti oluşturulurken Cifar-100[22] veri setinden faydalanılmıştır. Cifar-100 veri seti 100 farklı sınıftan oluşmakta ve her sınıfta 600 örnek bulunmaktadır. Bu örnekler 32x32 boyutunda renkli görüntülerdir. Önerilen çalışmada, özellik çıkarımında kullanılan CNN mimarisinin girişi de bu nedenle 32x32 olarak seçilmiştir.

Veri setinde odaklı parçalar doğrudan Cifar-100 veri setinden alınan 60.000 görüntüden oluşmaktadır. Odaksız yamalar oluşturulurken ise farklı filtre boyutlarında (3x3,5x5,7x7,9x9) gauss, hareket bulanıklaştırma yöntemleri uygulanarak 120.000 odaksız yama elde edilmektedir. Veri setlerinde farklı türde ve farklı büyüklükte bulanıklık içeren görüntüler bulunmaktadır. Bu nedenle önerilen çalışma için farklı değerlendirmeler ve denemeler yapılmış olup en uygun sonucun 3x3, 5x5 ve 7x7 filtre boyutu ile gauss ve hareket bulanıklaştırma yapıldığında alındığı görülmüştür. Ayrıca hareket (motion) bulanıklandırmasında bulanıklandırıcının yönü ve yoğunluğu parametreleri bulunmaktadır. Bu parametreler için optimum değerler farklı denemeler sonucunda sırasıyla 45 derece ve 0.5 olarak belirlenmiştir. Hem gauss hem de hareket bulanıklaştırma filtrelerinin farklı parametreleri için eğitimler yapılmış ve her bir filtre için parametreler belirlenmiştir. Eğitim veri seti toplamda 180.000 görüntüden oluşmaktadır. Çalışmada, odaklı yamalar için 1 etiketi verilirken odaksız yamalar için 0 etiketi verilmektedir. Ayrıca eğitim yapılırken veri setinin %70'i eğitim %30'u test verisi olarak kullanılmaktadır. Önerilen yaklaşımda test ve eğitim setleri ayrıştırılırken tabakalı örnekleme (stratified holdout) yöntemi kullanılmıştır. Tabakalı örnekleme, tüm popülasyondan verilerin rastgele seçilmesini içeren basit rastgele örneklemeden farklıdır. Bu yöntemde veri setindeki her olası örneğin eşit olasılıkla temsil edilmesini sağlar ve böylece veri setinin daha iyi kapsanması sağlanır.

2.2. Probleme uygun CNN mimarisi tasarlanması (Designing a CNN architecture suitable for the problem)

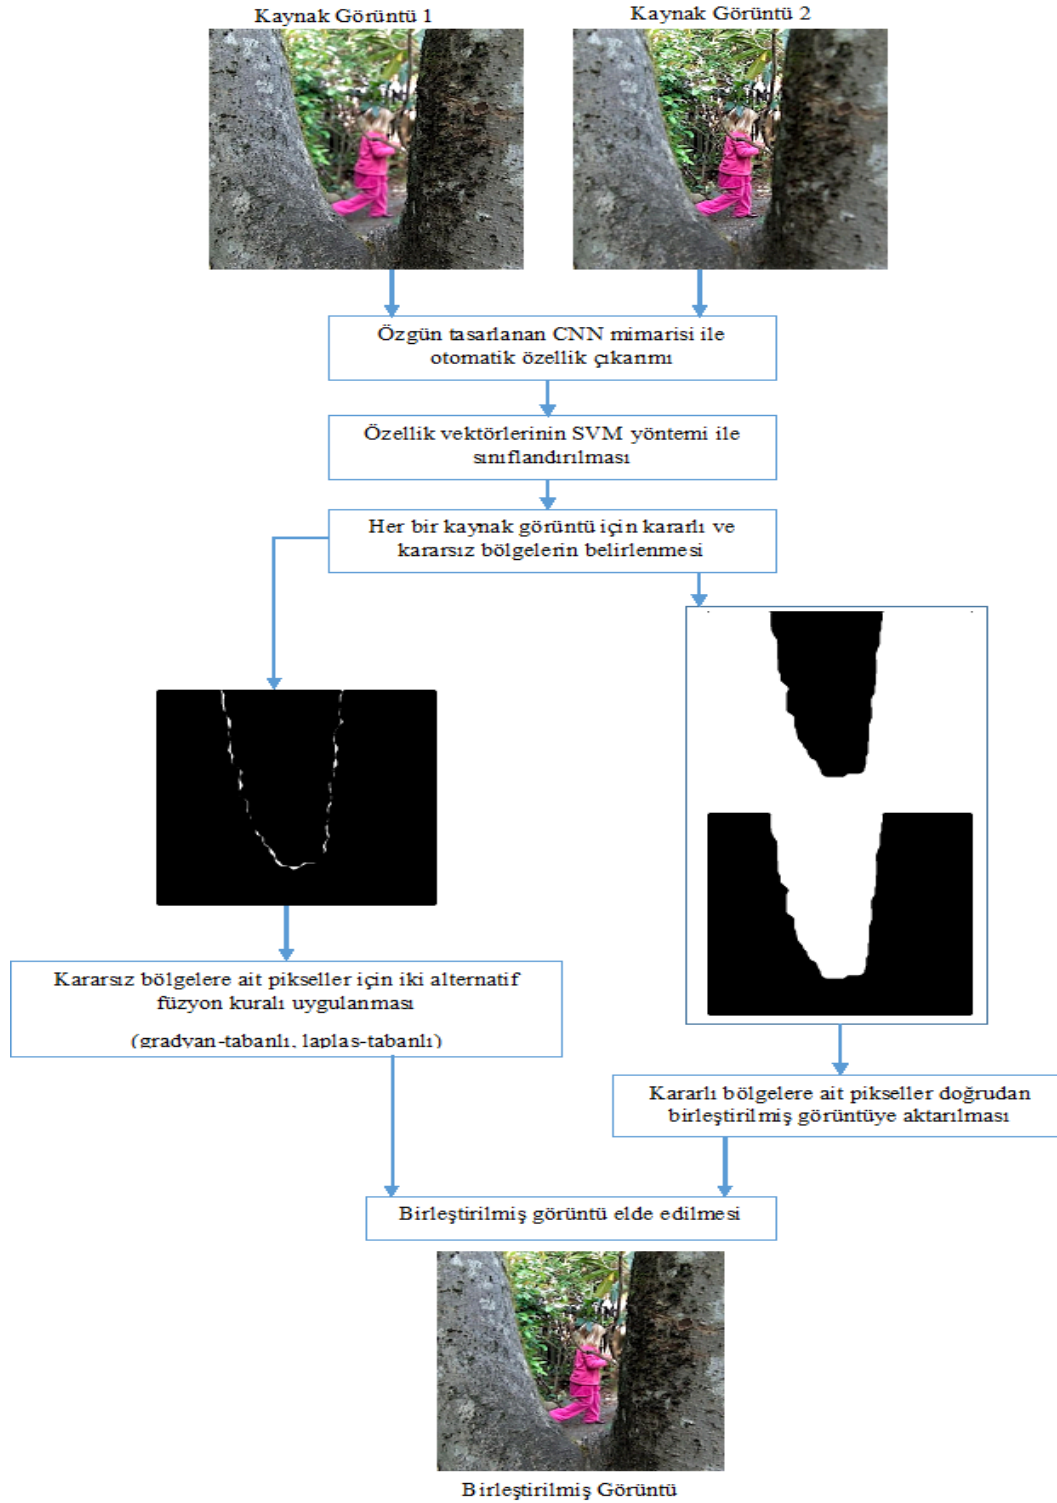
CNN mimarisi, sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Çoklu-odaklı görüntü birleştirme de CNN mimarisinin sıklıkla kullanıldığı alanlardan birisidir. Bu alanda derin öğrenme kullanılırken görüntü yamalarının odaklı veya odaksız olarak sınıflandırılması ele alınmaktadır. Literatürde, genellikle yeni bir ağ tasarlamak yerine önceden eğitilmiş ağlar tercih edilmektedir. Önceden eğitilmiş ağlar, çoğu alanda başarılı olsa da görüntü giriş boyutunun değiştirilememesi, gelişmiş sistemlere ihtiyaç duyması gibi dezavantajlara sahiptir. Ayrıca, literatürdeki çalışmalar derin ağları doğrudan sınıflandırma yapmak için kullanılmaktadır. Hâlbuki bu ağlar çok iyi birer özellik çıkarıcıdır. Önerilen çalışmada tasarlanan özgün CNN mimarisi basit sistemlerde çalışabilmekte, giriş boyutu esnek olarak değiştirilebilmektedir. Bu çalışma i5 8. Nesil işlemcili, 8GB belleğe sahip bir masaüstü bilgisayar ile yapılmıştır. Ayrıca çalışmada CNN mimarisinin insan gözetimi olmadan otomatik özellik çıkarımı özelliğinden faydalanılmıştır.

Tasarlanan CNN mimarisi, giriş, konvolüsyon, normalizasyon, aktivasyon ve tam-bağlantılı katmandan oluşmaktadır. Giriş katmanı, 32x32'lik görüntüleri girdi olarak almaktadır. Konvolüsyon katmanı, özellik çıkarımında önemli olup filtre boyutu ve filtre sayısı gibi parametreler almaktadır. Önerilen mimaride, 4 konvolüsyon katmanı bulunmakta her katmanda 3x3 boyutunda filtreler kullanılmaktadır. Filtre sayısı ise ağ derinleştikçe artmaktadır ve başlangıçtan son katmana doğru sırasıyla 48,96,128 ve 164 olarak seçilmektedir. Ayrıca, her bir konvolüsyon katmanını normalizasyon ve aktivasyon katmanları izlemektedir. Normalizasyon katmanı verileri belirli bir standart sapma etrafında toplayarak eğitimin hızlanmasını sağlamakta ve başlangıç parametrelerinin seçilmesinin önemini azaltmaktadır. Aktivasyon katmanı olarak, leakyRelu katmanı kullanılmaktadır. Bu katman hem pozitif hem de negatif değerlerin öğrenilmesine imkân sağlamaktadır. Böylece, gradyan ölmesi gibi sorunların önüne geçerek eğitimin başarılı bir şekilde yapılmasına olanak sağlamaktadır.

Öğrenme yöntemlerinde yaşanan en büyük sorunlardan birisi ağız ezberlemesidir. Ezberleme genellikle veri setlerinin düşük varyans dağılımına sahip olması ve veri setinin sığ olmasından kaynaklanmaktadır. Önerilen çalışmada bu sorunun önlenmesi için farklı parametreler kullanılmıştır. Veri setinin zenginleştirilmesi için ilgili veriye farklı transformasyonlar uygulanmaktadır. Böylece verinin sığ olmasından kaynaklanabilecek ezberlemenin önüne geçilmektedir. Ezberlemeye neden olan diğer bir durum veri setinin dağılımının düzenli olmamasıdır. Tasarlanan mimaride kullanılan batch normalizasyon katmanı verinin düzenlenmesine yardımcı olmaktadır. Ayrıca yine verinin düzenli hale getirilmesi için eğitim seçeneği olarak L2 düzenleştirmesi yöntemi veriye uygulanmıştır. Sonuç olarak hem veri seti zenginleştirilerek hem de veri dağılımı düzenli hale getirilerek ezberleme sorununun önüne geçilmiştir. CNN mimarileri için en önemli konulardan birisi de hiper parametrelerin seçimidir [25]. Bu mimarilerde genellikle öğrenme katsayısı, optimizasyon yöntemi, grup (batch) boyutu ve tur sayısı önemli parametrelerdendir. Önerilen çalışmada bu parametreler belirlenirken Grid Arama yöntemi kullanılmıştır. Böylece maksimum doğruluğu verebilecek optimum parametrelere ulaşılmıştır. Grid arama yöntemi sonucu öğrenme katsayısı 0.01, optimizasyon yöntemi adam, batch boyutu 8 ve tur sayısı 10 olarak belirlenmiştir. Bu parametreler kullanılarak ağ eğitilmiş ve özellik çıkarımına hazır hale getirilmiştir. Tasarlanan CNN mimarisi Şekil 2 ile gösterilir.

2.3. SVM yöntemi ile özelliklerin sınıflandırılması (Classification of features using SVM method)

Bir önceki bölümde CNN mimarisinin tasarlanması ve eğitilmesi anlatılmaktadır. Eğitilen bu mimari artık özellik çıkarımı için hazırdır. Özellik çıkarımı yapılırken, CNN mimarisinin son katmanında

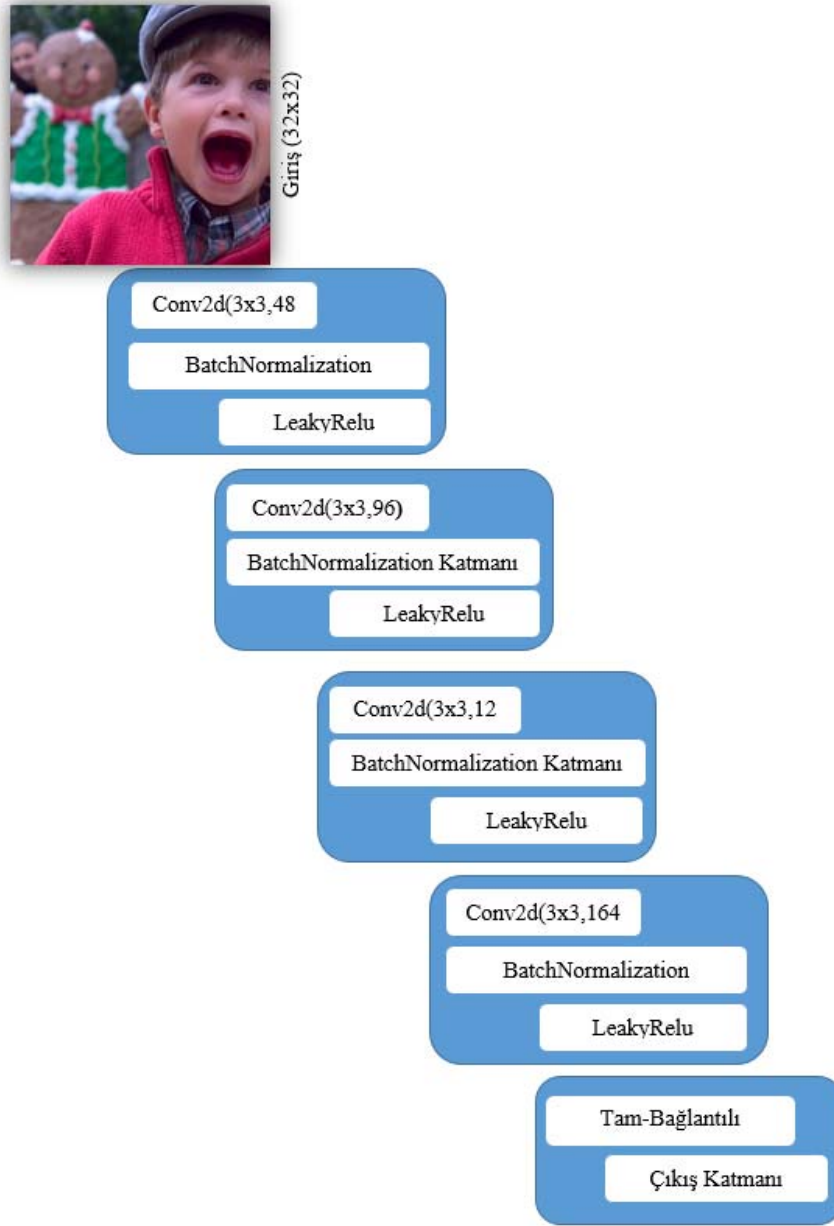


Şekil 1. Önerilen çalışmanın akış diyagramı (Flow diagram for proposed method)

bulunan tam-bağlantılı katman kullanılmıştır. Önerilen çalışmada, eğitilmiş ağdan elde edilen özelliklerin sınıflandırılması için SVM sınıflandırıcısı kullanılmıştır. Destek vektör makinesi, eğitim verilerindeki herhangi bir noktadan en uzak olan iki sınıf arasında bir karar sınırı bulan vektör uzayı tabanlı makine öğrenme yöntemidir [26]. Bu yöntemin, uygun bir çekirdek işlevi ile herhangi bir karmaşık sorunu çözebilmesi, yerel optimumlara takılmaması, yüksek boyutlu

verilerle de çalışabilmesi, ezberleme sorununun az olması gibi avantajları vardır. Bu avantajlar, SVM yöntemini her alanda cazip hale getirmektedir.

Önerilen çalışmada ilk olarak, Cifar-100 veri setinden elde edilen veri seti kullanılarak bu veri setindeki her bir görüntü için eğitilmiş CNN ağı ile özellik çıkarımı yapılır. Bu özellik vektörleri kullanılarak SVM



Şekil 2. Tasarlanan CNN mimarisi (Designed CNN architecture)

sınıflandırıcı modeli oluşturulur. SVM sınıflandırıcısının optimum parametreleri bulunurken Grid Arama yaklaşımı kullanılmış olup bu yaklaşım sonucunda en başarılı sonucu rbf çekirdeğinin verdiği tespit edilmiştir. Bu modelin başarısı test verisi kullanılarak test edilmektedir. SVM sınıflandırıcı modelinin başarısı doğruluk, duyarlık, özgüllük, hassasiyet metrikleri kullanılarak hesaplanmakta ve Tablo 1’de verilmektedir.

Tablo 1. SVM sınıflandırıcısı performans değerlendirmesi (SVM classifier performance evaluation)

SVM Sınıflandırıcı Başarısı				
Doğruluk	Duyarlık	Özgüllük	Hassasiyet	F-Ölçümü
0.996	0.998	0.9959	0.996	0.996

Tablodan görüleceği gibi SVM sınıflandırıcısı çoklu-odaklı görüntü yamalarının sınıflandırılmasında oldukça başarılıdır.

2.4. Uygulanan füzyon kuralları (Fusion rules)

Çoklu-odaklı görüntü birleştirme yöntemlerinde, başarıyı önemli derecede etkileyen faktörlerden birisi de füzyon kurallarının seçimidir. Seçilecek füzyon kuralı, kaynak görüntülerdeki odak bilgisini doğru olarak birleştirilmiş görüntüye aktarabilmeli ve kaynak görüntülerdeki kenar, köşe vb. gibi detay bilgilerini birleştirilmiş görüntüye aktarabilmelidir. Önerilen çalışma, kaynak görüntülerdeki piksellerin sınıflandırılması ve her bir kaynak görüntü için ikili karar haritaları oluşturulmasına dayanmaktadır. Ayrıca, çalışmada sınıflandırıcıların kararsız kaldığı durumlar da ayrı bir ikili haritada tutulmaktadır. Bu durum, dinamik etkili bir füzyon kuralı

oluşturulmasına olanak sağlamaktadır. Tasarlanan füzyon kuralında, kararlı bölgeler doğrudan birleştirilmiş görüntüye aktarılırken, kararsız bölgeler için iki alternatif füzyon kuralı önerilmektedir. Bu kurallar gradyan-tabanlı füzyon kuralı ve laplas-tabanlı füzyon kuralıdır.

Kararlı bölgeler için uygulanan füzyon kuralı Eş. 1 ile verilmektedir. Eşitlikte, birleştirilmiş görüntü BG, kaynak görüntü KG ve karar haritası KH ile temsil edilmektedir.

$$BG(i, j) = KH_{KG1}(i, j) \times KG1(i, j) + KH_{KG2}(i, j) \times KG2(i, j) \quad (1)$$

Kararsız bölgeler için alternatif füzyon kuralları kullanılmaktadır. Gradyan-tabanlı füzyon kuralı, görüntülerin analizinde iyi bir yardımcı olan gradyana dayanmaktadır. Gradyan, görüntülerin detay bileşenleri için yüksek değerler alırken, yumuşak geçişe sahip bölgelerde düşük değerler almaktadır. Bu analiz, detay bileşenlerini korumayı amaçlayan çoklu-odaklı görüntü birleştirme yöntemleri için oldukça uygundur. Gradyan-tabanlı füzyon kuralı adım adım aşağıdaki gibidir;

- İlk olarak her bir kaynak görüntü için gradyan büyüklükleri hesaplanır. İlk kaynak görüntü için bu büyüklükler $Gmag_1$ ile temsil edilirken ikinci kaynak görüntü için $Gmag_2$ ile temsil edilmektedir.
- İkinci aşama olarak kaynak görüntülerdeki karşılık düşen gradyan değerleri oranlanarak, karşılık düşen piksellerin birleştirilmiş görüntü için önem oranları bulunmaktadır. Önem oranlarının hesaplanması Eş. 2 ile verilmektedir. Eşitlikte önem oranları \ddot{O} ile temsil edilmektedir.

$$\ddot{O}(i, j) = \frac{Gmag_1(i, j)}{Gmag_1(i, j) + Gmag_2(i, j)} \quad (2)$$

- Son aşama birleştirme aşamasıdır ve Eş. 3 ile verilmektedir.

$$BG(i, j) = \ddot{O}(i, j) \times KG1(i, j) + (1 - \ddot{O}(i, j)) \times KG2(i, j) \quad (3)$$

Laplas, bir görüntünün ikinci uzamsal türevlerini hesaplayarak kenarları bulmayı amaçlayan bir operatördür. Tıpkı gradyan filtresi gibi, Laplas filtresi de piksel yoğunluklarının önemli ölçüde değiştiği bölgeleri vurgular. Bu nedenle çoklu-odaklı görüntü birleştirme için oldukça uygundur. Laplasın gradyana göre farklılığı görüntüyü daha iyi bastırması ve sadece görüntüdeki önemli bölgeleri vurgulamasıdır. Laplas-tabanlı füzyon kuralı da kararsız bölgeler için uygulanmış olup, işlem adımları aşağıdaki gibidir;

- İlk olarak her bir kaynak görüntü için laplas büyüklükleri hesaplanır. İlk kaynak görüntü için bu büyüklükler $Lapmag_1$ ile temsil edilirken ikinci kaynak görüntü için $Lapmag_2$ ile temsil edilmektedir.
- İkinci aşama olarak kaynak görüntülerdeki karşılık düşen gradyan değerleri oranlanarak, karşılık düşen piksellerin birleştirilmiş görüntü için önem oranları bulunmaktadır. Önem oranlarının hesaplanması Eş. 4 ile verilmektedir.

$$\ddot{O}(i, j) = \frac{Lapmag_1(i, j)}{Lapmag_1(i, j) + Lapmag_2(i, j)} \quad (4)$$

- Son aşama birleştirme aşamasıdır ve Eş. 5 ile verilmektedir.

$$BG(i, j) = \ddot{O}(i, j) \times KG1(i, j) + (1 - \ddot{O}(i, j)) \times KG2(i, j) \quad (5)$$

2.5. Performans ölçüm metrikleri (Performance measurement metrics)

Çoklu-odaklı birleştirme temel olarak kaynak görüntülerdeki doğru odak bilgisinin birleştirilmiş görüntüye aktarılmasını ve kaynak

görüntülerdeki doğru kenar, köşe vb. gibi önemli bilgilerin birleştirilmiş görüntüde korunmasını amaçlamaktadır. Bu amaçların ne kadar doğru olarak yerine getirildiği, performans ölçüm metrikleri ile ölçülmektedir. Bu çalışmada literatürde sıklıkla tercih edilen, Karşılıklı Bilgi (MI) [27], Petrovic vd. metriği ($Q^{AB/F}$) [28], Chen-Blum vd. metriği (Q_{CB}) [29], Düzlemsel Frekans (SF) [30], Yang vd. metriği (Q_Y) [31], Standart Sapma (STD) metrikleri tercih edilmektedir. MI metriği, kaynak görüntülerden birleştirilmiş görüntüye aktarılan doğru bilgi miktarını verir. $Q^{AB/F}$ metriği kaynak görüntülerden birleştirilmiş görüntüye aktarılan doğru kenar bilgisi oranı vermektedir. Q_{CB} metriği, Chen Blum tarafından önerilen ve insan görsel sistem modellerine dayalı bir kalite değerlendirme yöntemidir. SF ve STD metrikleri birleştirilmiş görüntüdeki detay bilgisi miktarını vermektedir. Q_Y , Yang vd. tarafından önerilen ve kaynak görüntüler ile birleştirilmiş görüntü arasındaki benzerliği kullanan objektif bir metriktir. Önerilen çalışmada, tüm bu metrikler yardımıyla çalışmanın performansı değerlendirilmiş ve karşılaştırmalar yapılmıştır. Kullanılan metriklerin detayları alt bölümlerde verilmektedir.

2.5.1. Karşılıklı bilgi (MI)

Karşılıklı bilgi metriği, kaynak görüntülerden birleştirilmiş görüntüye aktarılan doğru bilgi miktarını ölçmektedir. Bu metrik Eş. 6-Eş. 8 ile hesaplanmaktadır.

$$I_{AF} = \sum_{a,f} P_{AF}(a, f) \log \frac{P_{AF}(a, f)}{P_A(a)P_F(f)} \quad (6)$$

$$I_{BF} = \sum_{b,f} P_{BF}(b, f) \log \frac{P_{BF}(b, f)}{P_B(b)P_F(f)} \quad (7)$$

I_{AF} ve I_{BF} değerleri sırasıyla A görüntüsünden F görüntüsüne ve B görüntüsünden F görüntüsüne aktarılan bilgi miktarını gösterir. P ise entropiyi temsil eder. Bu değerler, kullanılarak Eş. 8'de toplam bilgi miktarı hesaplanır.

$$MI = I_{AF} + I_{BF} \quad (8)$$

2.5.2. Petrovic vd. metriği ($Q^{AB/F}$)

$Q^{AB/F}$ metriği, kaynak görüntülerdeki kenar bilgisinin birleştirilmiş görüntüde hangi oranda korunduğunu göstermektedir. Bu metrik, 0 ile 1 arasında değer almaktadır. Metrik sonucu, 1'e ne kadar yakında yöntem o kadar başarılıdır. Metrik Eş. 9-Eş. 13 yardımıyla hesaplanmaktadır.

$G^{AF}(n, m)$ ve $A^{AF}(n, m)$ sırasıyla A görüntüsünden F görüntüsüne aktarılan kenar bilgisinin gücü ve yönünü gösterir ve Eş. 9-Eş. 10 ile hesaplanır.

$$G^{AF}(n, m) = \begin{cases} \frac{g_F(n, m)}{g_A(n, m)}, & \text{if } g_A(n, m) > g_F(n, m) \\ \frac{g_A(n, m)}{g_F(n, m)}, & \text{otherwise} \end{cases} \quad (9)$$

$$A^{AF}(n, m) = \frac{|\alpha_A(n, m) - \alpha_F(n, m)| - \frac{\pi}{2}}{\frac{\pi}{2}} \quad (10)$$

$Q_g^{AF}(n, m)$ and $Q_a^{AF}(n, m)$ değerleri A ve F görüntüsünün kenar bağlantılarını verir. Bu eşitliklerde bazı sabitler kullanılır. Bu sabitler Γ_g , κ_g , σ_g ve Γ_a , κ_a , σ_a 'dir ve kenar gücünü hesaplamada kullanılır. Hesaplamalar Eş. 11-Eş. 12 ile verilmektedir.

$$Q_g^{AF}(n, m) = \frac{\Gamma_g}{1 + e^{\kappa_g(G^{AF}(n, m) - \sigma_g)}} \quad (11)$$

$$Q_a^{AF}(n, m) = \frac{\Gamma_a}{1 + e^{\kappa_a(A^{AF}(n,m) - \sigma_a)}} \quad (12)$$

Sonuç olarak Eş. 13 ile kaynak görüntülerden birleştirilmiş görüntüye aktarılan kenar miktarı bulunur.

$$Q^{AB/F} = \frac{\sum_{i=1}^M \sum_{j=1}^N (Q^{AF}(i,j)w^A(i,j) + Q^{BF}(i,j)w^B(i,j))}{\sum_{i=1}^M \sum_{j=1}^N (w^A(i,j) + w^B(i,j))} \quad (13)$$

2.5.3. Chen-Blum vd. metriği (Q_{CB})

İnsan görme sistemini temel alan Q_{CB} metriği[29], bir görüntü füzyon kalite değerlendirme yöntemidir. Metrik Eş. 14 ile hesaplanmaktadır.

$$Q_C(x, y) = \lambda_A(x, y)Q_{AF}(x, y) + \lambda_B(x, y)Q_{BF}(x, y) \quad (14)$$

Eşitlikte λ_A ve λ_B , A ve B kaynak görüntüleri için belirginlik haritasını vermektedir. Q_{AF} ve Q_{BF} değerleri ise kaynak görüntüler ile birleştirilmiş görüntü arasındaki kenar ilişkisini vermektedir.

2.5.4. Düzlemsel frekans (SF)

SF metriği, birleştirilmiş görüntüdeki kenar miktarını hesaplamada kullanılır. Hesaplamalar Eş. 15-Eş. 17 ile verilir.

$$SF = \sqrt{RF^2 + CF^2} \quad (15)$$

RF ve CF değerleri satır ve sütun frekanslarını ifade eder. RF değeri, görüntünün satırlarında bulunan kenar, köşe vb. bilgisini verirken CF, görüntülerin sütunlarından bulunan kenar, köşe vb. bilgilerini verir.

$$RF = \sqrt{\frac{1}{M \times N} \sum_{x=1}^M \sum_{y=2}^N [f(x, y) - f(x, y - 1)]^2} \quad (16)$$

$$CF = \sqrt{\frac{1}{M \times N} \sum_{x=2}^M \sum_{y=1}^N [f(x, y) - f(x - 1, y)]^2} \quad (17)$$

Bu eşitliklerde M ve N sırasıyla görüntünün satır ve sütun sayısını ifade ederken f ile orijinal sinyal ifade edilmektedir.

2.5.5. Yang vd. metriği (Q_Y)

Metriğimizin ilgi alanı, gereksiz bölgelerin ve tamamlayıcı/çakışan bölgelerin, kaynak görüntüler arasındaki yapısal benzerliğe göre sırasıyla ele alınması gerçeğinde yatmaktadır. Bu metrik Eş. 18-Eş. 19 kullanılarak hesaplanmaktadır.

$$Q_Y = \begin{cases} \lambda(w)SSIM(A, F|w) + (1 - \lambda(w))SSIM(B, F|w), & SSIM(A, F|w) \geq 0.75 \\ \max\{SSIM(A, F|w), SSIM(B, F|w)\}, & SSIM(A, F|w) < 0.75 \end{cases} \quad (18)$$

$$\lambda(w) = \frac{s(A|w)}{s(A|w) + s(B|w)} \quad (19)$$

Eşitlikte $s(A|w)$, w penceresi içindeki A görüntüsünün yerel belirginlik ölçüsüdür.

2.5.6. Standart Sapma (Standard Deviation)

Standart sapma metriği verinin dağılımını ölçmek için kullanılmaktadır. Bu metrik dolaylı olarak birleştirilmiş görüntüdeki önemli bilgi (kenar, köşe vb.) vermektedir. Metrik, Eş. 20 kullanılarak hesaplanmaktadır.

$$STD = \sum_{i=1}^n (x_i - \bar{x})^2 \quad (20)$$

Eşitlikte x ile veri, n ile verinin boyutu temsil edilmektedir. Verinin ortalaması \bar{x} ile verilmektedir.

3. Sonuçlar ve Tartışma (Results and Discussions)

Önerilen çalışma, çoklu-odaklı görüntü birleştirme amaçlarına uygun olarak hazırlanmış hibrit bir yaklaşım sunmaktadır. Bu çalışmanın değerlendirilmesinde objektif metrikler kullanılmıştır. Objektif metrikler, referans bir görüntüye ihtiyaç duymadan kaynak görüntülerden birleştirilmiş görüntülere aktarılan doğru odak bilgisi miktarını ölçmektedir. Bu nedenle, çalışmaların gerçek performansını ortaya koymada oldukça önemlidir. Önerilen çalışmada, denemeler hem Lytro veri setinde hem de gri seviye görüntülerden oluşan Durga Prasad veri seti üzerinde yapılmaktadır. Bu bölümde, önerilen çalışmanın bu veri setleri üzerindeki görsel ve sayısal sonuçları verilecektir.


Lytro veri seti, renkli görüntülerden oluşan 20 setten oluşmaktadır. Bu veri seti, literatürde sıklıkla tercih edilmektedir. Bu bölümde Lytro veri setinden alınan Lytro-03, Lytro-08, Lytro-09 ve Lytro-10 ve Çiçek görüntüleri için görsel sonuçlar verilecektir. Ayrıca, Lytro veri setindeki tüm görüntüler için Q_{CB} , SF, STD, $Q^{AB/F}$ ve Q_Y objektif metrikleri hesaplanmış olup bu değerlerin ortalamaları sonuçlar da verilecektir.

Şekil 3-Şekil 7, Lytro veri seti ve Durga Prasad veri setinden alınan örneklerin önerilen çalışma sonrası çıktılarını vermektedir. Şekillerde a ve b görüntüleri veri setlerinden alınan odak dışı nesnelere içeren ham görüntüleri vermektedir. c ve d görüntüleri, önerilen çalışma sonrası ortaya çıkan karar haritalarını vermektedir. Karar haritalarından görüleceği üzere önerilen çalışma, odaklı ve odaksız bölgeleri net olarak ortaya çıkarmaktadır. e görüntüsü ise önerilen yaklaşım sonrası oluşturulan tüm-odaklı birleştirilmiş görüntüyü vermektedir. Birleştirilmiş görüntü, bulanık alanlardan giderilmiş net bir görüntüdür.

Lytro veri setinden alınan tüm örnekler için MI, Q_{CB} , $Q^{AB/F}$ ve STD metrikleri hesaplanmış olup Tablo 2 ile verilmektedir. Bu metrikler kullanılarak önerilen yaklaşım literatürdeki yedi farklı yaklaşımla karşılaştırılmıştır.

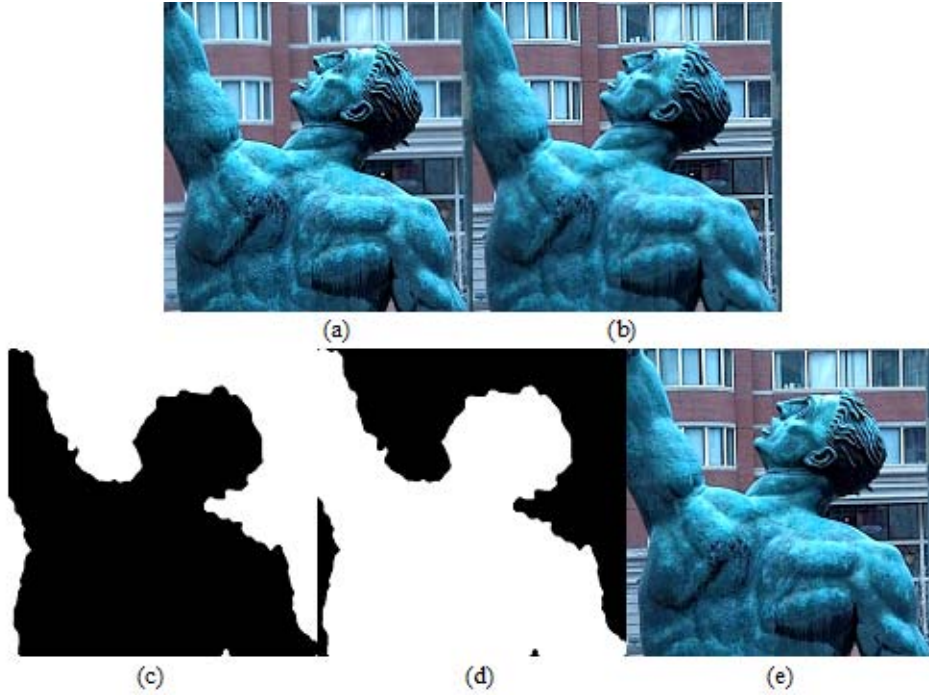
Tablo incelendiğinde, önerilen yöntemin hem gradyan hem de laplas-tabanlı füzyon kuralı kullanılarak elde edilen sonuçları görülmektedir. İlgili veri seti için en iyi sonuçlar kalın yapılmıştır. Ayrıca bu çalışmada kararsız bölge tespiti yapılmasının yöntem başarısına etkisini gösterebilmek için sonuçlar kararsız bölge tespiti yapılmadan ve yapılar ayrı ayrı alınmıştır. Kararsız bölge tespiti yapılmadan yöntem sonuçları tabloda Önerilen Çalışma (KBTY) olarak ifade edilmektedir. KBTY, kararsız bölge tespiti yapılmayan ifadesinin kısaltılmasıdır. Sonuçlar incelendiğinde, gradyan-tabanlı ve laplas-tabanlı füzyon kuralları ile yapılan birleştirme performanslarının birbirlerine oldukça yakın olduğu ve literatürdeki yaklaşımlardan önerilen çalışmanın daha üstün olduğu çıkarılmaktadır. Tablo da seçilen metrikler, kaynak görüntülerden birleştirilmiş görüntüye aktarılan doğru bilgi miktarını ölçmektedir. Dolayısıyla sonuçlar bu doğrultuda değerlendirildiğinde, önerilen çalışmanın çoklu-odaklı görüntü birleştirme amaçlarına uygun olduğunu görülmektedir.

Lytro veri setinden alınan örnekler için ayrıca Q_Y ve SF metrikleri kullanılarak da performans değerlendirmesi yapılmıştır. Önerilen yaklaşım Q_Y metriği kullanılarak 8 farklı yaklaşım ile karşılaştırılarak SF metriği kullanılarak 5 farklı yaklaşımla karşılaştırılmıştır. Karşılaştırma sonuçları sırasıyla Şekil 8 ve Şekil 9 ile verilmektedir.



Şekil 3. Çoklu-odaklı Lytro-03 görüntüsü, a) Kaynak görüntü 1, b) Kaynak görüntü 2, c) Karar haritası 1, d) Karar haritası 2, e) Birleştirilmiş görüntü.

(Multi-focus Lytro-03 image, a) Source image 1, b) Source image 2, c) Decision map 1, d) Decision map 2, e) Fused image)



Şekil 4. Çoklu-odaklı Lytro-08 Görüntüsü, a) Kaynak Görüntü 1, b) Kaynak Görüntü 2, c) Karar Haritası 1, d) Karar Haritası 2, e) Birleştirilmiş Görüntü

(Multi-focus Lytro-08 image, a) Source image 1, b) Source image 2, c) Decision map 1, d) Decision map 2, e) Fused image)


Şekiller incelendiğinde, önerilen yaklaşımın her iki metrik için de literatürdeki yaklaşımlardan daha iyi sonuçlar ürettiği görülmektedir. Sonuçlar değerlendirildiğinde, önerilen yaklaşımın görüntüleme cihazlarından kaynaklanan odaklanma problemine çözüm olarak kullanılabileceği çıkarılmaktadır.

Lytro veri setinin yanında, içerisinde çok fazla görüntü barındırmayan gri seviyeli Durga Prasad veri seti için de değerlendirmeler yapılmaktadır. Bu veri setinden alınan ve bu alanda popüler olan Kitap, Disk ve Pepsi görüntüleri için önerilen çalışmanın objektif hesaplamaları gerçekleştirilmektedir. Bu hesaplamalarda, MI, $Q^{AB/F}$,



Şekil 5. Çoklu-odaklı Lytro-09 Görüntüsü, a) Kaynak Görüntü 1, b) Kaynak Görüntü 2, c) Karar Haritası 1, d) Karar Haritası 2, e) Birleştirilmiş Görüntü.

(Multi-focus Lytro-09 image, a) Source image 1, b) Source image 2, c) Decision map 1, d) Decision map 2, e) Fused image)




Şekil 6. Çoklu-odaklı Çiçek görüntüsü, a) Kaynak görüntü 1, b) Kaynak görüntü 2, c) Karar haritası 1, d) Karar haritası 2, e) Birleştirilmiş görüntü

(Multi-focus Flower image, a) Source image 1, b) Source image 2, c) Decision map 1, d) Decision map 2, e) Fused image

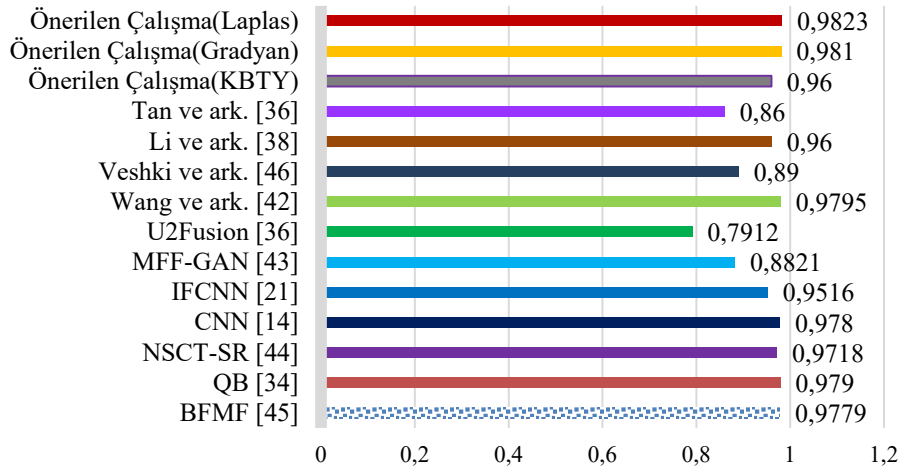
SF, Q_Y ve Q_{CB} metrikleri kullanılmaktadır. Pepsi görüntüsü için MI ve $Q^{AB/F}$ metrikleri hesaplanmış olup literatürdeki 12 farklı yaklaşımla karşılaştırılmıştır. Karşılaştırma sonuçları Tablo 3 ile verilmiştir. MI ve $Q^{AB/F}$ metrikleri literatürde sıklıkla kullanılan ve yöntemlerin performansını net olarak ortaya koyan metriklerdir. Tablo incelendiğinde, gradyan-tabanlı ve laplas-tabanlı füzyon kurallarını içeren önerilen çalışmanın literatürdeki çalışmalara göre

başarılı olduğu görülmektedir. Literatürdeki çalışmaların dezavantajları odaklı bölgelerden odaksız bölgelere geçişleri göz ardı etmeleridir. Bu nedenle, kenarları yumuşak görüntüler elde etmektedirler. Bu durum, sayısal sonuçlara etki etmektedir. Kitap görüntüsü için önerilen çalışmada SF, Q_{CB} ve Q_Y metrikleri hesaplanmış, sonuçlar literatürdeki 8 farklı yaklaşımla karşılaştırılmıştır. Sonuçlar, Tablo 4 ile verilmektedir.



Şekil 7. Çoklu-odaklı Lytro-10 görüntüsü, a) Kaynak görüntü 1, b) Kaynak görüntü 2, c) Karar haritası 1, d) Karar haritası 2, e) Birleştirilmiş görüntü
(Multi-focus Lytro-10 image, a) Source image 1, b) Source image 2, c) Decision map 1, d) Decision map 2, e) Fused image)

QY Metriği için Karşılaştırmalar



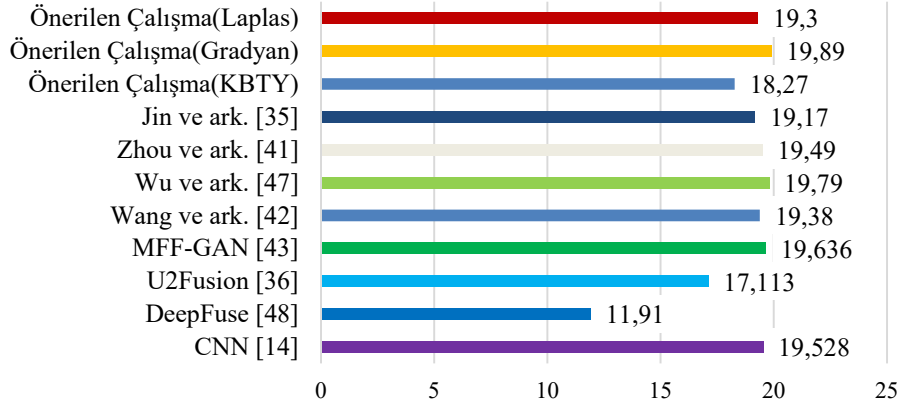
Şekil 8. Q_Y metriği ile karşılaştırma sonuçları (Results of comparison with the QY metric)

Tablo incelendiğinde önerilen yaklaşımın, SF ve Q_Y metrikleri için literatürdeki çalışmalardan daha iyi sonuçlar verdiği görülmektedir. Q_{CB} metriği için literatür çalışmalarına yakın sonuçlar vermektedir. SF, metriği objektif bir metrik olup kaynak görüntülerden birleştirilmiş görüntüye aktarılan yüksek frekanslı bileşenlerin (kenar, köşe vb.) miktarını ölçmektedir. Önerilen çalışma, odaklı bölgelerden odaksız bölgelere geçişleri de hesaba katması ve bu bölgelerde yoğun kenar bilgileri olmasından dolayı literatür çalışmalarına oranla daha başarılı olmaktadır. Q_Y metriği ise birleştirilmiş görüntü ve kaynak görüntüler arasındaki benzerliklerden yola çıkmaktadır. Önerilen çalışmanın, yüksek doğrulukla odaklı bölge tespiti yapması ve geçiş bölgelerini de doğru bir şekilde birleştirilmiş görüntüye aktarması kaynak görüntülere benzer birleştirilmiş görüntüler oluşmasını sağlamaktadır.

Q_{CB} metriği ise görüntü parlaklık değerlerini kullanarak yöntemlerin performansını ölçmektedir. Yöntemlerde yapılan ön işlemler ya da kullanılan füzyon kuralı birleştirilmiş görüntüdeki kontrast değerlerini etkilemektedir. Daha parlak bir görüntüde bu metrik yüksek sonuçlar verirken daha mat bir görüntüde daha düşük değerler verebilmektedir. Renk değişimlerine hassas olan bu metrikte bu nedenlerle yakın sonuçlar görmek mümkündür. Son olarak, Disk görüntüsü için sonuçlar Tablo 5 ile verilmektedir.

Tablolar ve grafikler genel olarak incelendiğinde önerilen çalışmanın hem gradyan-tabanlı hem de laplas-tabanlı füzyon kuralı içeren formunun literatürdeki çalışmalardan üstün olduğu görülmektedir. Önerilen çalışmanın, özgün olarak tasarlanan CNN mimarisi ile

SF Metriği için Karşılaştırmalar



Şekil 9. SF metriği ile karşılaştırma sonuçları (Results of comparison with the SF metric)

özelli çıkarması yapması, kararsız bölgelerin çıkarılması ve bu bölgelerin etkili füzyon kuralları ile birleştirilmesi gibi özelliklerinin sonuçlara etkisi görülmektedir. Literatürdeki çalışmalar genellikle basit füzyon kuralları ile birleştirme yapmakta ve kararsız bölgeleri göz ardı etmektedir. Bu problemlerin önerilen çalışma ile giderildiği sonuçlar ile kanıtlanmaktadır.

Tablo 2. Lytro Veri seti için karşılaştırma sonuçları (Comparison results for the Lytro dataset)

	MI	Q_{CB}	$Q^{AB/F}$	STD
MST-SR [32]	5,15	0,76	0,74	57,42
FusionGAN [33]	3,5	0,5	0,37	48,35
ECNN [16]	6,15	0,8072	0,75	57,51
CNN [14]	5,96	0,8084	0,7618	57,46
QB [34]	5,55	0,7827	0,7446	57,5385
IFCNN [21]	4,8797	0,7292	0,7296	57,5502
U-NET [35]	6,1358	0,5642	0,6382	X
U2Fusion [36]	7,82	X	0,75	57,52
Bouzos vd.[37]	7,36	0,7557	0,7143	X
Li vd. [38]	6,78	0,7347	0,6779	X
Tan vd. [39]	6,44	0,63	0,5147	X
Li vd. [40]	6,99	0,7176	0,697	X
Zhou vd.[41]	8,3	0,6	0,74	X
Önerilen Çalışma(KBTY)	7,59	0,75	0,82	56,88
Önerilen Çalışma (Gradyan)	8,85	0,8024	0,8945	61,98
Önerilen Çalışma (Laplas)	8,86	0,8133	0,892	59,64

Tablo 3. Pepsi Görüntüsü için objektif karşılaştırma sonuçları (Objective comparison results for the Pepsi image)

	MI	$Q^{AB/F}$
Yin vd. [49]	5,16	0,78
Nejati vd. [50]	8,87	0,78
Chen vd. [51]	7,42	0,75
He vd. [52]	8,1	0,78
Hua vd. [53]	7,8	0,76
Zhang vd. [54]	7,09	0,78
Yang vd. [55]	8,23	0,73
Liu vd. [56]	8,66	0,79
GFDF [57]	3,28	0,63
DTCWTGF [57]	3,17	0,52
MFDWT [57]	3,02	0,38
IPGF [57]	3,49	0,69
Önerilen Çalışma(KBTY)	7,17	0,69
Önerilen Çalışma (Gradyan)	8,97	0,87
Önerilen Çalışma (Laplas)	8,54	0,86

Tablo 4. Kitap görüntüsü için objektif karşılaştırma sonuçları (Objective comparison results for the Book image)

	SF	Q_Y	Q_{CB}
GFF [58]	30,5275	0,9633	0,8664
ASR [59]	30,4693	0,9527	0,8624
QUADTREE [59]	30,6982	0,9763	0,8742
DSIFT [59]	27,3718	0,964	0,8705
CNN [14]	30,5258	0,9753	0,8768
MADCNN [59]	29,7434	0,9554	0,8511
IFCNN [21]	32,7881	0,8579	0,7407
Wang vd. [59]	30,7202	0,9782	0,8783
Önerilen Çalışma(KBTY)	26,41	0,9488	0,8553
Önerilen Çalışma (Gradyan)	34,21	0,98	0,8723
Önerilen Çalışma (Laplas)	34,45	0,982	0,865

Tablo 5. Masa Görüntüsü için objektif karşılaştırma sonuçları (Objective comparison results for the Desk image)

	SF	Q_Y	Q_{CB}
GFF [58]	18,741	0,9538	0,7287
ASR [59]	18,6605	0,9181	0,706
QUADTREE [59]	18,9445	0,9694	0,7524
DSIFT [59]	18,9672	0,9272	0,7243
CNN [14]	18,7777	0,968	0,7499
MADCNN [59]	18,7407	0,9528	0,7199
IFCNN [21]	18,4182	0,9027	0,6829
Wang vd. [59]	18,8789	0,985	0,7689
Önerilen Çalışma(KBTY)	16,41	0,9735	0,7663
Önerilen Çalışma (Gradyan)	20,42	0,99	0,7751
Önerilen Çalışma (Laplas)	20,13	0,987	0,7732

4. Sonuçlar (Conclusions)

Görüntüleme cihazlarının artmasıyla, görüntü sayısında ciddi oranda artış yaşanmış ve bu durum görüntüler üzerindeki çalışmalarını da hızlandırmıştır. Çoklu-odaklı görüntü birleştirme, görüntülerde oluşan odak problemlerinin giderilmesi için ortaya atılmıştır. Görüntülerin detaylı incelenmesi için görüntülerdeki tüm nesnelerin net olması oldukça önemlidir. Önerilen çalışmada, görüntülerin incelenmesini kolaylaştıracak yeni bir hibrit yaklaşım önerilmiştir. Bu yaklaşımda, CNN mimarisinin çok fazla tercih edilmeyen fakat pahalı donanımlara ihtiyacı azaltan otomatik özellik çıkarımından faydalanılmıştır. Yine basit ve etkili sınıflandırma yapma becerisine sahip SVM sınıflandırıcısı yardımıyla çıkarılan bu

özellikler maksimum doğrulukla sınıflandırılmıştır. Çalışmayı öne çıkaran özelliklerden birisi de her bir kaynak görüntü için karar haritaları oluşturulması böylece sınıflandırıcıların kararsız bölgeler durumlarının da ortaya çıkarılabilmesidir. Kararsız bölgeler, birleştirilmiş görüntülerin kalitesini artırmada oldukça önemlidir. Çünkü, sınıflandırıcılar genellik odaklı bölgelerden odaksız bölgelere geçiş noktalarını içeren bu bölgelerde hatalı sonuçlar üretmektedir. Bu bölgelerin göz ardı edilmesi, birleştirilmiş görüntüde bulanık alanların kalmasına neden olacaktır. Bu nedenle, önerilen çalışmada bu bölgelerin belirli bir kurala göre aktarılması oldukça önemlidir. Çalışma, farklı füzyon kurallarının analizini gerçekleştirerek gelecek çalışmalara yön vermeye çalışmaktadır. Sonuçlar incelendiğinde, önerilen çalışmanın en fazla 6GB bellek gereksinimi ile etkili birleştirme sonuçları ürettiği gözlemlenmektedir.

Teşekkür (Acknowledgement)

Yazar, çalışmanın gelişimini olumlu yönde etkileyen yorumları için editör ve inceleyicilere teşekkür eder.

Kaynaklar (References)

1. Akbulut H., Aslantaş V., Multi-exposure image fusion using convolutional neural network, *Journal of the Faculty of Engineering and Architecture of Gazi University* 38 (3), 1439-1451, 2023.
2. Jiang Z., Han D., Chen J., Zhou X., A wavelet based algorithm for multi-focus micro-image fusion, *Third International Conference on Image and Graphics (ICIG'04)*, Hong Kong, China, 176-179, 18-20 Aralık 2004.
3. Sujatha K., Punithavathani D. S., Optimized ensemble decision-based multi-focus image fusion using binary genetic Greywolf optimizer in camera sensor networks, *Multimedia Tools and Application.*, 77 (2), 1735-1759, 2018.
4. Chen Z., Wang D., Gong S., Zhao F., Application of multi-focus image fusion in visual power patrol inspection, *IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, Chongqing, China, 1688-1692, 25-26 Mart 2017.
5. Xiao G., Bavirisetti D.P., Liu, G., Zhang, X., Decision-Level Image Fusion. In *Image Fusion*, Springer, Singapore, 2020.
6. Li H., Liu L., Huang W., Yue C., An improved fusion algorithm for infrared and visible images based on multi-scale transform, *Infrared Physics and Technology*, 74, 28-37, 2016.
7. Jin X., Hou J., Nie R., Yao S., Zhou D., Jiang Q., He K., A lightweight scheme for multi-focus image fusion, *Multimedia Tools and Application*, 77 (18), 20286-20302, 2018.
8. Petrovic V., Xydeas C., Gradient-based multiresolution image fusion, *IEEE Transactions on Image Processing*, 13 (2), 228-237, 2004.
9. Yang B., Li S., Multi-focus image fusion and restoration with sparse representation, *IEEE Transactions on Instrumentation and Measurement*, 59 (4), 884-892, 2010.
10. Liu W., Wang Z., A novel multi-focus image fusion method using multi-scale shearing non-local guided averaging filter, *Signal Processing*, 166, 107252, 2020.
11. Li S., Kang X., Hu J., Yang B., Image matting for fusion of multi-focus images in dynamic scenes, *Information Fusion*, 14 (2), 147-162, 2013.
12. Li S., Kwok J., Wang Y., Combination of images with diverse focuses using the spatial frequency, *Information Fusion*, 2 (3), 169-176, 2001.
13. Li M., Cai W., Tan Z., A region-based multi-sensor image fusion scheme using pulse-coupled neural network, *Pattern Recognition Letters*, 27 (16), 1948-1956, 2006.
14. Liu Y., Chen X., Peng H., Wang Z., Multi-focus image fusion with a deep convolutional neural network, *Information Fusion*, 36, 191-207, 2017.
15. Tang H., Xiao B., Li W., Wang G., Pixel convolutional neural network for multi-focus image fusion, *Information Sciences*. 433, 125-141, 2018.
16. Amin-Naji M. Aghagolzadeh A. Ezoji, M, Ensemble of CNN for multi-focus image fusion, *Information Fusion*, 51, 201-214, 2019.
17. Ma B., Zhu Y., Yin X., Ban X., Huang H., Mukeshimana, M, Sef-fuse: An unsupervised deep model for multi-focus image fusion, *Neural Computing and Application*, 33 (11), 5793-5804, 2020.
18. Yan X., Gilani S., Qin H., Mian A., Unsupervised deep multi-focus image fusion, *ArXiv*, 1806.07272v1, 2018.
19. Jung H., Kim Y., Jang H., Unsupervised deep image fusion with structure tensor representations, *IEEE Transaction on Image Processing*, 29, 3845-3858, 2020.
20. Gai D., Shen X., Chen H., Su P., Multi-focus image fusion method based on two-stage of convolutional neural network, *Signal Processing*, 176, 107681, 2020.
21. Zhang Y., Liu Y., Sun P., IFCNN: a general image fusion framework based on convolutional neural network, *Information Fusion*, 54, 99-118, 2020.
22. <https://www.cs.toronto.edu/~kriz/cifar.html>, Erişim 11 Mayıs 2022
23. <https://mansournejati.ece.iut.ac.ir/content/lytro-multi-focus-dataset>, Erişim 11 Mayıs 2022.
24. <https://sites.google.com/view/durgaprasadbavirisetti/datasets?authuser=0>, Erişim 11 Mayıs 2022.
25. Uğurlu M., Doğru İ.A., Arslan R.S., Detection and classification of darknet traffic using machine learning methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (3), 1439-1451, 2023.
26. Sevli O., Diagnosis of diabetes mellitus using various classifiers, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (2), 989-1001, 2023.
27. Qu G., Zhang D., Yan P., Information measure for performance of image fusion, *Electronics Letters*, 38 (7), 313-315 2002.
28. Xydeas C., Petrovic V., Objective image fusion performance measure, *Electronics Letters*, 36 (4), 308-309, 2000.
29. Chen Y., Blum R.S., A new automated quality assessment algorithm for image fusion, *Image and Vision Computing*, 27 (10), 1421-1432, 2009.
30. Eskicioglu A.M., Fisher P.S., Image quality measures and their performance, *IEEE Transactions on Communication*, 43 (12), 2959-2965 1995.
31. Yang C., Zhang J.Q., Wang X. R., Liu, X., A novel similarity based quality metric for image fusion, *Information Fusion*, 9 (2), 156-160, 2008.
32. Liu Y., Liu S., Wang Z., A general framework for image fusion based on multi-scale transform and sparse representation, *Information Fusion*, 24, 147-164, 2015.
33. Ma J., Yu W., Liang P., FusionGAN: a generative adversarial network for infrared and visible image fusion, *Information Fusion*, 48, 11-26, 2019.
34. Bai X., Zhang Y., Zhou F., Quadtree-based multi-focus image fusion using a weighted focusmeasure, *Information Fusion* 22, 105-118, 2015.
35. Jin X., Xi X., Zhou D., Ren X., Yang J., Jiang Q., An unsupervised multi-focus image fusion method based onTransformer and U-Net, *IET Image Processing*, 17 (3), 733-746, 2022.
36. Xu H., Ma J., Jiang J., Guo X., Ling H., U2fusion: A unified unsupervised image fusion network, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44 (1), 502-518, 2022.
37. Bouzou O., Andreadis I., Mitianoudis N., Conditional Random Field-Guided Multi-Focus Image Fusion, *Journal of Imaging*, 8 (9),240,2022.
38. Li B., Peng H., Wang J., A novel fusion method based on dynamic threshold neural systems and nonsubsampling contourlet transform for multi-modality medical images, *Signal Processing*, 178, 107793, 2021.
39. Tan W., Thiton W., Xiang P., Zhou H., Multi-modal brain image fusion based on multi-level edge-preserving filtering, *Biomed. Signal Process. Control*, 64, 102280, 2021.
40. Li X., Zhou F., Tan H., Joint image fusion and denoising via three-layer decomposition and sparse representation, *Knowledge Based Systems*, 224, 107087, 2021.
41. Zhou D., Jin X., Jiang Q., Cai L., Lee S., Yao S., MCRD-Net: An unsupervised dense network with multi-scale convolutional block attention for multi-focus image fusion, 16 (6), 1558-1574, 2022.
42. Wang J., Qu H., Wei Y., Xie M., Xu J., Zhang Z., Multi-focus image fusion based on quad-tree decomposition and edge-weighted focus measure, *Signal Processing*, 198, 108590, 2022.
43. Zhang H., Le Z., Shao Z., Xu H., Ma J., MFF-GAN: An unsupervised generative adversarial network with adaptive and gradient joint constraints for multi-focus image fusion, *Information Fusion*, 66, 40-53, 2020.

44. Liu Y., Liu S., Wang Z., A general framework for image fusion based on multi-scale transform and sparse representation, *Information Fusion*, 24 (1), 147–164, 2015.
45. Zhang Y., Bai X., Wang T., Boundary finding based multi-focus image fusion through multi-scale morphological focus-measure, *Information Fusion*, 35, 81–101, 2017.
46. Veshki F.G., Vorobyov S.A., Coupled Feature Learning Via Structured Convolutional Sparse Coding for Multimodal Image Fusion. In *Proceedings of the ICASSP 2022–2022 IEEE International Conference on Acoustics, Speech and Signal Processing ICASSP*, Singapore, 2500–2504, 2022.
47. Wu K., Mei Y., Multi-focus image fusion based on unsupervised learning, *Machine Vision and Applications*, 33, 75, 2022.
48. Ram Prabhakar K., Sai Srikar V., Venkatesh Babu R., Deepfuse: A deep unsupervised approach for exposure fusion with extreme exposure image pairs, *Proceedings of the IEEE international conference on computer vision*, Cambridge, Amerika Birleşik Devletleri, 4714-4722, 6 Ağustos 2002.
49. Yin H., Li Y., Chai Y., Liu Z., Zhu Z., A novel sparse-representation-based multi-focus image fusion approach, *Neurocomputing*, 216, 216–229, 2016.
50. Nejati M., Samavi S., Karimi N., Soroushmehr SMR., Shirani S., Roosta I., Najarian K., Surface-area based focus criterion for multi-focus image fusion, *Information Fusion*, 36, 284–295, 2017.
51. Chen C., Gend P., Lu K., Multi-focus image fusion based on multiwavelet and DFB, *Chemical Engineering Transactions*, 46, 277–283, 2015.
52. He K., Zhou D., Zhang X., Nie R., Multi-focus: focused region finding and multi-scale transform for image fusion, *Neurocomputing*, 320, 157–170, 2018.
53. Hua K. L., Wang H. C., Rusdi A. H., Jiang S. Y., A novel multi-focus image fusion based on random walks, *Journal of Visual Communication and Image Representation*, 25 (5), 951–962, 2014.
54. Zhang B., Lu X., Pei H., Liu H., Zhao Y., Zhou W., Multi-focus Image fusion algorithm based on focused region extraction, *Neurocomputing*, 174, 733–748, 2016.
55. Yang Y., Que Y., Huang S., Lin P., Technique for multi-focus image fusion based on fuzzy-adaptiv pulse-coupled neural network, *SIVip*, 11 (3), 439–446, 2017.
56. Liu S., Lu Y., Wang J., Hu S., Zhao J., Zhu Z., A new focus evaluation operator based on max-min filter and its application in high-quality multi-focus image fusion. *Multidimensional System and Signal Processing*, 31 (2), 569–590, 2020.
57. Jagtab N. S., Thepade S. D., High-quality image multi-focus fusion to address ringing and blurring artifacts without loss of information., *The Visual Computer*, 36, 4353-4371, 2022.
58. Li L., Ma H., Jia Z., Si Y., A novel multiscale transform decomposition-based multi-focus image fusion framework. *Multimedia Tools and Application*, 80 (8), 12389–12409, 2021.
59. Wang X., Hua Z., Li J., Multi-focus image fusion framework based on transformer and feedback mechanism, *Ain Shams Engineering Journal*, 14 (5), 101978, 2022.