



Araştırma Makalesi / Research Article
**ÇOKLU-ODAKLI GÖRÜNTÜLERİN GENETİK ALGORİTMA
KULLANILARAK BİRLEŞTİRİLMESİ**

Veysel ASLANTAŞ, Ahmet Nusret TOPRAK*, Rifat KURBAN, Emre BENDEŞ

Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, KAYSERİ

Geliş/Received: 11.02.2013 Kabul/Accepted: 21.05.2013

ÖZET

Görüntü birleştirme, bilgisayarla görme ve görüntü işleme sahasında büyük öneme sahip bir konu olarak öne çıkmaktadır. Aynı çevrenin görüntülediği, farklı optik parametrelerle elde edilmiş çoklu-odaklı görüntüler birleştirilerek oluşturulan tamamı net görüntüler, birçok endüstriyel ve bilimsel sahada uygulama alanı bulmaktadır. Bu çalışmada resim uzayı tabanlı yeni bir çoklu-odaklı görüntü birleştirme yöntemi önerilmektedir. Önerilen yöntemde öncelikle, genetik algoritmaya dayalı bir teknik kullanılarak, çoklu-odaklı görüntülerde oluşan bulanık bölgelere ait nokta dağılım fonksiyonları saptanır. Daha sonra, elde edilen nokta dağılım fonksiyonları kullanılarak kaynak görüntüler bulanıklaştırılır. Son aşamada, kaynak görüntüleri ve bulanıklaştırılan yapay görüntüleri kullanan bir karar mekanizması yardımıyla tespit edilen kaynak görüntülerdeki net piksellerin taşınmasıyla tamamı net bir sonuç görüntü üretilir. Ayrıca, önerilen yöntem literatürde tanımlanmış klasik yöntemlerle sayısal ve görsel olarak karşılaştırılmıştır. Elde edilen sonuçlar önerilen yöntemin üstünlüğünü ortaya koymaktadır.

Anahtar Sözcükler: Görüntü birleştirme, genetik algoritma, sınırlı alan derinliği.

FUSION OF MULTI FOCUS IMAGES USING GENETIC ALGORITHM

ABSTRACT

In applications of imaging systems, one major problem is limited depth of field which results in blurring parts of the captured image. However, in many areas such as microscopic imaging, industrial machine vision and surveillance applications, images that have large depth of field are preferred. In this paper, a novel multi-focus image fusion method is presented. The method, firstly, calculates optical transfer function of blurred parts located on source images by using a technique based on genetic algorithm. Then source images are artificially blurred by employing obtained transfer functions and sharp pixels of sources images are detected by using artificially blurred and source images. Eventually, sharp pixels of source images are transferred to build everywhere-in-focus fused image. Furthermore, proposed method and classical methods are compared in terms of quantitative and visual evaluation. According to the results of evaluations, proposed method outperforms classic methods.

Keywords: Multi-focus image fusion, genetic algorithm, depth of field.

* Corresponding Author/Sorumlu Yazar: e-mail/e-ileti: antoprak@erciyes.edu.tr, tel: (352) 207 66 66 / 32601

1. GİRİŞ

Sayısal kamera uygulamalarında meydana gelen en temel problemlerden birisi, görüntüde bulanık bölgelerin oluşmasına neden olan sınırlı alan derinliğidir [1]. Görüntüleme cihazlarında lens belirli uzaklıktaki bir cisme odaklandığında, bu cisimle aynı uzaklıkta bulunan tüm cisimler net olarak görüntülenecektir. Buna karşın, farklı uzaklıkta bulunan cisimler odak dışında kalacak ve bulanık olarak görüntülenecektir [2]. Kabul edilebilir netlikte görüntülenen, en yakın ve en uzak nesnelerin arasındaki mesafe, alan derinliği olarak nitelendirilir. Net görüntülerde bulanık görüntülerden daha fazla bilgi ihtiva edildiğinden; mikroskobik görüntüleme, endüstriyel bilgisayarla görme, güvenlik uygulamaları gibi birçok sahada geniş alan derinliğine sahip görüntüler tercih edilmektedir [3].

Alan derinliğinin artırılması için farklı yöntemler tercih edilebilmektedir. Örneğin, görüntü alınırken küçük diyafram açıklığı kullanılması elde edilen görüntülerin alan derinliğini artıracaktır. Ancak, küçük diyafram açıklığı, görüntüde bozulma meydana getiren kırınım etkisine neden olmaktadır. Ayrıca, küçük diyafram açıklığında ışık kazancı azalacağından pozlama süresinin uzatılması gerekecektir. Bu dezavantajlar küçük diyafram açıklığı kullanarak görüntü elde etmeyi pratik uygulamalarda kullanışsız kılmaktadır [2].

Bir çevrenin tamamen net görüntüsü, çevrenin bulanık görüntüsüne uygulanacak bir dekonvolüsyon işlemi sonucunda elde edilebilir. Bu işlemi gerçekleştirebilmek, kameraya ait parametrelerin ve kamera kalibrasyon parametrelerinin kullanılması ile erişilebilecek noktasal dağılım fonksiyonunun bilinmesi ile mümkün olmaktadır. Buna karşın, çoğu pratik uygulamada bu parametreler bilinmemekte yahut hassas olarak elde edilememektedir [4].

Sınırlı alan derinliğinin artırılması için bahsedilen farklı yöntemler arasında çoklu-odaklı görüntü birleştirme teknikleri öne çıkmaktadır. Çoklu-odaklı görüntü birleştirme, aynı çevrenin, sabit bir noktaya konumlandırılmış bir sayısal kamera ile her seferinde farklı odak parametreleri kullanılarak alınmış görüntülerinin birleştirilerek bu kaynak görüntülerdeki bütün net bölgeleri ihtiva eden tek bir net görüntünün elde edilmesi işlemidir. Literatürde, insan/makine algısını artırmak için kaynak görüntülerden daha fazla görsel bilgiye sahip birleşik görüntüler oluşturmak amacıyla geliştirilmiş birçok çoklu-odaklı görüntü birleştirme yöntemi tanımlanmıştır. Görüntü birleştirme yöntemleri temel olarak dönüşüm uzayı ve resim uzayı yöntemleri olmak üzere iki gruba ayrılmaktadır [5].

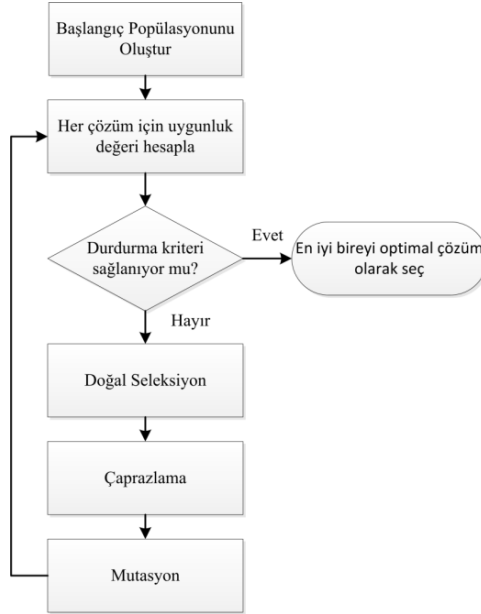
Dönüşüm uzayı yöntemlerinde öncelikle kaynak görüntüler bir dönüşüm işlemine tabi tutularak dönüşüm uzayına aktarılır. Dönüşüm uzayında tanımlanan birleştirme kurallarına göre, birleştirme işlemi gerçekleştirildikten sonra elde edilen bu birleşik veriden ters dönüşüm işlemi kullanılarak birleşik görüntü elde edilir. Dönüşüm uzayı tekniklerinin en bilinen örnekleri piramit dönüşümler ve dalgacık dönüşümleridir. Piramit dönüşümü tabanlı yöntemlere örnek olarak Laplacian piramit [6], gradyent piramit [7] ve morfoloji piramit [8] yöntemleri verilebilir. Literatürde tanımlanmış dalgacık dönüşümü kullanan yöntemlere örnek olarak ise ayrık dalgacık dönüşümü [9] ve kaymadan bağımsız dalgacık dönüşümü [10] metotları verilebilir. Dönüşüm uzayı yöntemleri genellikle yapılarındaki küresel işlemlerden dolayı kaynak görüntülerdeki kaymalardan ve gürültülerden fazlaca etkilenmektedir. Ayrıca bünyelerinde dönüşüm ve ters dönüşüm gibi işlemler barındırmalarından dolayı uygulanması ve anlaşılması karmaşık bir yapıya sahiptirler.

Dönüşüm uzayı yöntemlerinin aksine resim uzayı yöntemleri, kaynak görüntüleri, herhangi bir dönüşüme tabi tutmadan, doğrudan görüntü uzayı öznitelikleri kullanılarak yapılan değerlendirmeler sonucu birleştirmektedir. Resim uzayı birleştirme teknikleri piksel tabanlı ve bölgesel tabanlı olarak iki grupta incelenebilir. Piksel tabanlı yöntemler görüntüler üzerinde gerçekleştirilen incelemeler sonucu net pikselleri birleşik görüntüye taşır. Bölgesel tabanlı yöntemlerde ise kaynak görüntüler, bölgelere ayrıldıktan sonra net olduğu belirlenen bölgeler taşınarak birleşik görüntü inşa edilir [5, 11, 12].

Bu çalışmada sınırlı alan derinliğini artırmak için yeni bir piksel tabanlı görüntü birleştirme yöntemi önerilmektedir. Önerilen yöntem, bir çevreye ait bulanık bir görüntünün, aynı çevrenin tamamı net görüntüsü ile görüntünün elde edildiği algılayıcının nokta dağılım fonksiyonunun (NDF) konvolüsyonuna eşit olduğu varsayımına dayanmaktadır. Nokta dağılım fonksiyonu, dağılım parametresine (σ) bağlı olduğundan kaynak görüntüler kullanılarak tüm görüntüler için dağılım parametreleri, genetik algoritma yardımıyla bulunur. Bulunan dağılım parametreleri ile hesaplanan nokta dağılım fonksiyonları kullanılarak görüntülerdeki net pikseller tespit edilir. Bu piksellerin taşınmasıyla birleşik net görüntü inşa edilir [13].

2. GENETİK ALGORİTMA

İlk kez 1975 yılında Holland tarafından önerilen genetik algoritma (GA), yönlendirilmiş rastgele araştırma teknikleri kullanan sezgisel bir araştırma algoritmasıdır [14]. GA, canlılarda bulunan genetik gelişimi taklit etmekte ve bireylerin rekabeti ilkesine dayanmaktadır. GA, belirli bir problemin olası çözümlerini kromozom benzeri bir veri yapısı şeklinde kodlayarak olası çözüm popülasyonu oluşturur ve bu bireylere genetik operatörler uygulayarak en uygun (optimal) çözümü arar. Popülasyonlar her nesilde tabii seçme (natural selection), çaprazlama (crossover) ve mutasyon (mutation) genetik operatörleri kullanılarak sürekli olarak gelişir. Algoritma problemin optimal çözümünü son jenerasyonun en kaliteli bireyi olarak belirler.



Şekil 1. Genetik Algoritma Akış Diyagramı

Algoritmaya ilk olarak başlangıç popülasyonu oluşturularak başlanır. Araştırma amaçlı çalışmalarda, başlangıç popülasyonu genellikle rastgele çözümler üretilerek oluşturulur. Şayet başlangıçta bazı çözümler biliniyorsa başlangıç popülasyonu bu çözümler kullanılarak oluşturulabilir. Olası çözümler genellikle ikili bit dizisi şeklinde kodlanarak ifade edilir. Popülasyon oluşturulduktan sonra popülasyondaki her bireyin uygunluk değeri hesaplanmaktadır. Bu amaçla kullanılan uygunluk fonksiyonu, her bireyin temsil ettiği çözümün kullanımıyla veya yeteneğiyle orantılı olan sayısal bir uygunluk değeri verir. Bu bağlamda, çözümlerin kalitesini

tespit etmek için kullanılan uygunluk fonksiyonu algoritmanın performansı açısından oldukça önemlidir.

GA, oluşan her nesle genetik operatörler uygulayarak daha uygun çözümler taşıyan nesiller üretmeyi amaçlar. Algoritmanın kullandığı temel genetik operatörlerden ilki, kalitesi (uygunluk değeri) yüksek bireylerin hayatta kalması ve sayılarının artması, kalitesi düşük bireylerin ise sayılarının azalarak kaybolması prensibiyle çalışan tabii seçme işlemidir. Bir önceki nesilden daha iyi nitelikler içeren yeni kromozomlar oluşturmak amacıyla çaprazlama operatörü kullanılmaktadır. Buna göre, mevcut bireylerden birer çift rastgele seçilir ve çaprazlama operatörü yardımıyla bu iki bireyden yeni iki birey türetilir. En basit çaprazlama tekniği olarak; bireyler üzerinde rastgele seçilen bir noktadan sonrası bireyler arasında yer değiştirilir. Popülasyonu oluşturan bireylerin içermediği, araştırılmamış çözümlerin bulunması için mutasyon operatörü kullanılır. Mutasyon oranına göre bireylere ait belirli bitler tersine çevrilerek mutasyon işlemi gerçekleştirilir. Her yeni nesil; tabii seçme, çaprazlama ve mutasyon işlemleri sonucu oluşmakta ve bir sonraki neslin ebeveynleri olmaktadır. Bu süreç, önceden belirlenen nesil sayısı kadar ya da durdurma kriteri sağlanıncaya kadar devam eder. Süreç sonunda en yüksek uygunluk değerine sahip çözüm optimal çözüm olarak belirlenir [15, 16].

3. BULANIK GÖRÜNTÜ TEORİSİ

Görüntüleme cihazlarında görüntünün oluşumu, üç boyutlu görüntü uzayındaki nesnelere, 2 boyutlu algılayıcı düzlemine mesafe ağırlıklı iz düşümü olarak tanımlanır [17].

Bir optik sistemin dönüşümü, konvolüsyon işlemiyle modellenilebilir. Bulanık görüntü, bir süper pozisyon integrali ile ifade edilir:

$$i(x, y) = \iint h(x - \xi, y - \eta, d(\xi, \eta))s(\xi, \eta) d\xi d\eta \quad (1)$$

burada x ve y resim uzayı koordinatları ξ ve η uzaysal değişkenler, $s(x, y)$ kaynak görüntünün ve $i(x, y)$ algılayıcı düzleminin irradiyans dağılımları, $d(x, y)$ nesne ile net görüntü düzlemi arasındaki uzaklık ve $h(x, y, d)$ NDF'yi temsil etmektedir.

Eğer nesne ile net görüntü düzlemi arasındaki uzaklık (d) sabitse NDF, $h(x, y)$ şeklinde ifade edilebilir. Böylece bulanık görüntü takip eden denklemde olduğu gibi bir konvolüsyon integrali olarak ifade edilebilir.

$$i(x, y) = \iint h(x - \xi, y - \eta)s(\xi, \eta) d\xi d\eta \quad (2)$$

Konvolüsyon işlemi genellikle \otimes simgesi ile ifade edildiğinden, denklem (2) kısaca şu şekilde ifade edilebilir:

$$i(x, y) = h(x, y) \otimes s(x, y) \quad (3)$$

Yapılan çalışmalar sonucunda, NDF'nin en iyi olarak iki boyutlu Gaussian fonksiyonu ile ifade edildiği ortaya konmuştur. σ dağılım parametresi olmak şartıyla NDF aşağıdaki şekilde ifade edilir [4]:

$$h(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (4)$$

4. ÇOKLU ODAKLI GÖRÜNTÜLERİN BİRLEŞTİRİLMESİ

Çoklu odaklı kaynak görüntüler, algılayıcının aynı anda tek düzleme odaklanabilmesi nedeni ile meydana gelen sınırlı alan derinliği problemi sebebi ile odaklı (net) ve odak dışı (bulanık) bölgelerden oluşmaktadır. Önceki bölümde değinildiği gibi bulanık görüntüler, net görüntülerin NDF ile konvolüsyonu olarak ifade edilebilirler. Çoklu-odaklı kaynak görüntülerde, görüntülen

çevredeki bir nesnenin, hem bulanık hem net görüntüsü bulunduğundan, bulanık görüntüyü oluşturan NDF bulunabilir. Bir başka deyişle, çevredeki bir nesne, kaynak görüntülerden birinde net olarak görüntülenirken, diğerinde bulanık olarak görüntülenmektedir. Böylece, bu nesnenin bulunduğu ilişkili görüntü bölgeleri kullanılarak nesnenin bulanık görüntüsüne ait NDF hesaplanabilir.

Basitlik için aynı çevrenin görüntülediği, yakın odaklı i_1 ve uzak odaklı i_2 kaynak görüntülerinin bulunduğunu varsayalım. Görüntünün ön plan ve arka plan bileşenleri sırasıyla f ve g olarak tanımlansın. Yakın odaklı i_1 görüntüsünde ön planda bulunan f bölgesi odaklı, arka planda bulunan g bölgesi odak dışı ve uzak odaklı i_2 görüntüsünde ön planda bulunan f bölgesi odak dışı, arka planda bulunan g bölgesi odaklı olarak elde edilecektir. Bu durumda, görüntülerdeki bulanık bölgeleri, aynı bölgenin net görüntüsü ile ilgili NDF'nin konvolüsyonu olarak tanımlayabildiğimizden, i_1 ve i_2 görüntüleri takip eden denklemlerle ifade edilebilir.

$$\begin{aligned} i_1(x, y) &= f(x, y) + h_1(x, y) \otimes g(x, y) \\ i_2(x, y) &= h_2(x, y) \otimes f(x, y) + g(x, y) \end{aligned} \quad (5)$$

Kaynak görüntülerdeki bulanık bölgeler bir başka kaynak görüntüde net olarak bulunmaktadır. Buradan hareketle, kaynak görüntüler diğer kaynak görüntünün NDF'si ile konvolve edilerek bulanıklaştırılırsa, NDF'si kullanılan kaynak görüntüdeki bulanık bölge aynı bulanıklık derecesiyle üretilmiş olur. Bu maksatla i_1 görüntüsü, i_2 görüntüsünün NDF'si h_2 ile konvolve edilerek, i_1^* görüntüsü üretilir. Benzer şekilde i_2 görüntüsünün h_1 ile konvolüsyonu neticesi i_2^* görüntüsü ortaya çıkar. i_1^* ve i_2^* görüntülerinin oluşumu denklem (6)'da verilmektedir.

$$\begin{aligned} i_1^*(x, y) &= h_2(x, y) \otimes f(x, y) + h_2(x, y) \otimes (h_1(x, y) \otimes g(x, y)) \\ i_2^*(x, y) &= h_1(x, y) \otimes (h_2(x, y) \otimes f(x, y)) + h_1(x, y) \otimes g(x, y) \end{aligned} \quad (6)$$

Denklem (5) ve (6) incelendiğinde görülebileceği gibi; f için bulanıklık derecesi i_1^* ve i_2 görüntülerinde aynıdır. Benzer şekilde, i_1 ve i_2^* görüntülerinde g aynı bulanıklığa sahiptir. Bu sayede, kaynak görüntüler bulanıklaştırılarak oluşturulan i_1^* ve i_2^* görüntüleri yardımıyla kaynak görüntülerdeki bulanık ve net bölgeler belirlenebilir. Görüntülerdeki hangi pikselin bulanık, hangi pikselin net olduğunun belirlenmesi için kullanılacak fark görüntülerin üretilmesi denklem (7)'de verilmiştir.

$$\begin{aligned} d_1(x, y) &= |i_1(x, y) - i_2^*(x, y)| \\ d_2(x, y) &= |i_2(x, y) - i_1^*(x, y)| \end{aligned} \quad (7)$$

Denklem (5) ve (6)'daki değerler denklem (7)'de yerine konursa fark görüntüleri aşağıdaki şekilde oluşur.

$$\begin{aligned} d_1(x, y) &= (f(x, y) - h_1(x, y) \otimes (h_2(x, y) \otimes f(x, y))) + 0 \\ d_2(x, y) &= 0 + (g(x, y) - h_2(x, y) \otimes (h_1(x, y) \otimes g(x, y))) \end{aligned} \quad (8)$$

İdeal olarak, işlemlerde kaynak görüntülere ait NDF'ler kullanıldığı zaman oluşan fark görüntülerin noktasal çarpımı sonucu elde edilecek matrisin toplamı sıfır olacaktır. Bu prensip kullanılarak kaynak görüntülere ait NDF'ler hesaplanabilir. Daha sonra hesaplanan NDF'ler kullanılarak birleştirme işlemi gerçekleştirilecektir.

$$\sum (d_1 \cdot d_2) = 0 \quad (9)$$

4.1. Kaynak Görüntüleri Ait NDF'lerin Hesaplanması

Literatürde aynı sahneye ait net ve bulanık görüntüleri kullanarak NDF'nin bulunmasına yönelik analitik yöntemler tanımlanmıştır. Bu makalede ise NDF, GA kullanılarak optimal olarak hesaplanmaktadır. Önerilen yöntemde, NDF'nin hesaplanması için gerekli olan değişken dağılım parametresi σ olduğu için, GA kullanılarak σ değeri araştırılmaktadır. Şekil 2'de NDF'lerin hesaplanması için önerilen yöntem görülmektedir.

Elde edilen d_1 ve d_2 fark görüntülerinin noktasal çarpımı sonucu oluşan matrisin değerleri toplamı minimize edilerek σ araştırılmaktadır. Optimizasyon algoritmasının her nesli için bulunan σ değerleri kullanılarak kaynak görüntüleri ait NDF'ler üretilir. Üretilen NDF'ler kullanılarak fark görüntüleri bulunur ve bu işlemler durdurma kriteri sağlanıncaya kadar devam ettirilir. Durdurma kriteri sağlandığında, oluşan son nesle ait en kaliteli değer optimal σ olarak atanır. Bulunan optimal σ değerleri kullanılarak elde edilen NDF'ler yardımı ile birleştirme işlemi gerçekleştirilir.

4.2. Birleşik Görüntünün Elde Edilmesi

Birleştirme safhasında önceki bölümde GA kullanılarak elde edilen NDF'lerden yararlanılarak görüntülerdeki net pikseller tespit edilir ve birleşik görüntüye taşınır.

Elde edilen fark görüntüleri kullanılarak kaynak görüntülerde hangi piksellerin net olduğu tespit edilir ve net pikseller kullanılarak birleşik görüntü oluşturulabilir. Bu amaçla fark görüntülerin piksel piksel karşılaştırıldığı bir karar mekanizması kullanılır. Birleşik görüntünün (i_F), x, y görüntü koordinatlarındaki piksel değeri, denklem (10)'da verilen yapıyla seçilir.

$$i_F(x, y) = \begin{cases} i_1(x, y), & d_1(x, y) \geq d_2(x, y) \\ i_2(x, y), & d_1(x, y) < d_2(x, y) \end{cases} \quad (10)$$

Eğer herhangi bir görüntü koordinatı için d_1 'in mutlak değeri d_2 'den büyük veya eşitse bu koordinattaki piksel i_1 görüntüsünden, eğer küçükse i_2 görüntüsünden taşınmaktadır. Bütün piksel değerleri için bu işlem gerçekleştirilerek birleşik görüntü inşa edilir

5. DENEYSEL ÇALIŞMA

Bu bölümde, önerilen yöntemi, klasik yöntemlerle karşılaştırmak için yapılan deneysel çalışmaların sonuçlarına yer verilmektedir. Görüntü birleştirme yöntemlerinin performansını değerlendirmek üzere tanımlanmış değerlendirme metrikleri, referans bir görüntü kullanıp kullanmadıklarına göre sınıflandırılırlar. Eğer kullanılan görüntü setinde referans bir görüntü bulunuyorsa, referans görüntü ile üretilen birleşik görüntüyü karşılaştırarak görüntü birleştirme yöntemini değerlendiren referans tabanlı metriklerden faydalanılabilir. Ancak görüntü setinde referans bir görüntü bulunmuyor ise yalnızca üretilen birleşik görüntü üzerinden değerlendirme yapan objektif metrikler kullanılabilir.

5.1. Referans Tabanlı Metrikler

Referans tabanlı metrikler görüntü birleştirme yöntemlerinin kalitelerini, üretilen birleşik görüntü ile referans görüntüyü kullanarak, hata ya da benzerlik hesaplarıyla değerlendirir. Genellikle referans tabanlı metriklerin sonuçlarının görsel değerlendirmeye uyduğu söylenebilir. Bu çalışmada referans tabanlı metriklerden tepe sinyal-gürültü oranı (PSNR) ve yapısal benzerlik (YB) kullanılmıştır.

PSNR bir işaretin mümkün olan maksimum gücünün o işareti bozan görüntünün gücüne oranıdır [5]. İşaretlerin birçoğu çok geniş bir dinamik aralığa sahip olduklarından, PSNR genelde logaritmik desibel ölçeğinde ifade edilir.

$$PSNR = 10 \log_{10} \left(\frac{\max^2}{\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (R(i, j) - F(i, j))^2} \right) \quad (11)$$

Denklemden R ve F sırasıyla referans ve birleşik görüntüyü temsil etmekte, \max ise görüntünün maksimum piksel değerini ifade etmektedir. Bu çalışmada yapılan deneylerde görüntüler 8 bitlik olarak kodlandığı için \max değeri 255 olmaktadır.

Referans görüntü kullanan metriklerden bir diğeri **Yapısal Benzerlik** (**YB**) [18]. PSNR'nin insan algısıyla uyummadığı bazı durumlar bulunmaktadır. Bu sebeple, YB, diğer metriklerin kısıtlamalarını ortadan kaldırmak için geliştirilmiştir. YB metriği takip eden denklemde verilmiştir.

$$YB(R, F) = \frac{(2\mu_R\mu_F + c_1)(2\sigma_{RF} + c_2)}{(\mu_R^2 + \mu_F^2 + c_1)(\sigma_R^2 + \sigma_F^2 + c_2)} \quad (12)$$

burada μ_R ve μ_F sırasıyla R ve F görüntülerinin ortalaması, σ_R R 'nin varyansı, σ_F F 'nin varyansı, σ_{RF} R ve F 'nin kovaryansı, $c_1 = (k_1L)^2$ ve $c_2 = (k_2L)^2$ işlemi kararlı hale getirmek için kullanılmış değişkenler, L piksellerin alabileceği değer aralığı (deneylerde 8-bit kodlanmış gri seviye görüntüler kullanıldığı için $L=255$ alınmıştır), k_1 ve k_2 sırasıyla 0.01 ve 0.03 değerleri verilmiş sabitlerdir.

5.2. Objektif metrikler

Pratikte, çoklu-odaklı görüntü birleştirme uygulamalarında referans görüntüler mevcut değildir. Bu sebeple gerçek görüntülerin kullanıldığı deneylerde yalnızca objektif metrikler kullanılmaktadır. Objektif metrikler birleştirme kalitesini ölçmek için referans görüntüye gerek duymaz ve hesaplamayı birleşik görüntü ve/veya kaynak görüntüleri kullanarak yapar. Bu bölümde objektif metriklerden birleştirme faktörü (BF) ve kenar tabanlı kalite (KTK) metrikleri tanıtılmaktadır.

BF, kaynak görüntüler ile birleşik görüntü arasındaki karşılıklı bilgiyi ölçerek değerlendirme yapan bir kalite metriğidir [19]. Kaynak görüntülerden taşınan bilgiler üzerinden değerlendirme yapan BF'nin hesaplanması için öncelikle tüm kaynak görüntüler ile birleşik görüntüler arasındaki karşılıklı bilgi (KB) aşağıdaki denklem yardımıyla hesaplanır:

$$KB_{GF} = \sum_{i,j} P_{GF}(i, j) \log \frac{P_{GF}(i, j)}{P_G(i)P_F(j)} \quad (13)$$

burada P_{GF} , G ve F görüntülerinin normalize edilmiş, birleştirilmiş gri seviye histogramını, P_G ve P_F ise her iki görüntünün normalize edilmiş marjinal histogramını temsil etmektedir.

Daha sonra tüm kaynak görüntüler ile birleşik görüntü arasındaki KB değerleri hesaplanarak toplanır ve böylece BF değeri aşağıdaki şekilde bulunur:

$$BF = \sum_K KB_K \quad (14)$$

KTK, birleştirme işleminin kalitesini hesaplamak için kaynak görüntülerden birleştirilmiş görüntüye taşınan kenar bilgilerini değerlendirmektedir [20]. Objektif kalite metriği

$KTK^{AB/F}$ her iki kaynak görüntünün normalize edilmiş kenar bilgilerinin ağırlıklandırılmasıyla, takip eden denklem biçiminde elde edilir:

$$KTK^{AB/F} = \frac{\sum_{i=1}^N \sum_{j=1}^M Q^{AF}(i,j)\omega^A(i,j) + Q^{BF}(i,j)\omega^B(i,j)}{\sum_{i=1}^N \sum_{j=1}^M (\omega^A(i,j) + \omega^B(i,j))} \quad (15)$$

Burada $\omega^A(i,j)$ ve $\omega^B(i,j)$ kaynak görüntülerin Sobel kenar bilgisine dayalı ağırlıklandırma katsayıları ve Q^{AF} ile Q^{BF} A, B'nin F ile arasındaki kenar koruma değerleridir. KTK metriği 0 ile 1 arasında değer üretir.

5.3. Deneyler

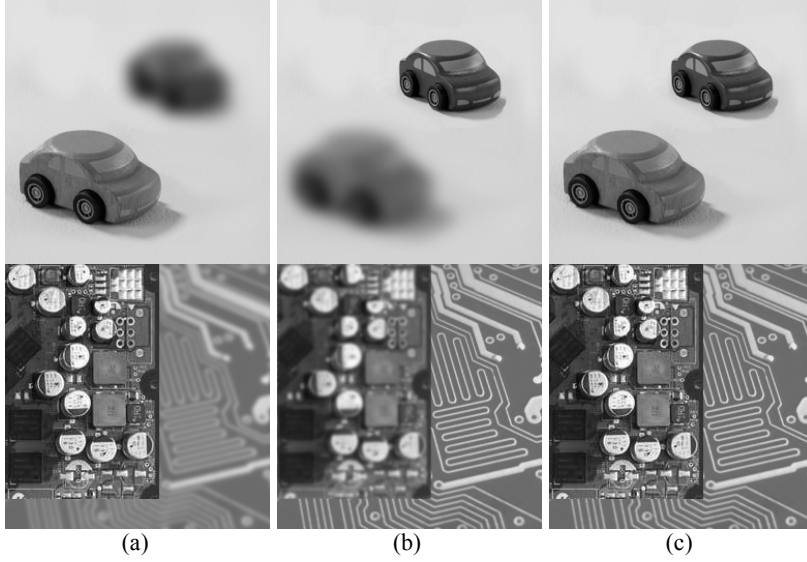
Bu bölümde öncelikle, önerilen yöntemde kullanılan genetik algoritmanın parametrelerinde yapılan değişikliğin yonteme etkisi incelenmiştir. Daha sonra, önerilen yöntem, literatürde iyi bilinen yöntemlerden Laplacian piramit (LP) [6], Ayrık Dalgacık Dönüşümü (ADD) [9] ve resim uzayı blok seçme (RUBS) [12] yöntemleri ile görsel ve sayısal açıdan karşılaştırılarak değerlendirilmiştir.

Yapılan deneylerde öncelikle farklı GA parametrelerinin yöntemin başarısına etkisi gözlenmiştir. Çizelge 1.'de Saat görüntüsü kullanılarak yapılan deneylerde GA parametrelerinde yapılan değişikliklerin objektif metrik sonuçlarına etkisi görülmektedir. Çizelgede popülasyon sayısının 20, jenerasyon sayısının 250 olması ve popülasyon sayısının 50, jenerasyon sayısının 100 olması durumları için çaprazlama oranı 0.3, 0.6, 0.9 değerleri, mutasyon oranı 0.1, 0.3, 0.6 değerleri için denenmiştir. Çizelge 1. incelendiğinde görüleceği üzere farklı GA parametreleri kullanılmasının yöntemin başarımına etkisi ciddi boyutlarda olmadığı gözlemlenmektedir. Bu da yöntemin kararlılığını göstermektedir.

Çizelge 1. Saat görüntüsü için 30 bağımsız koşmanın ortalama KTK ve BF değerleri


		KTK			BF		
		CR=0.3	CR=0.6	CR=0.9	CR=0.3	CR=0.6	CR=0.9
P=20	MR=0.1	0,7232	0,7228	0,7223	9,3048	9,3041	9,2991
JEN=250	MR=0.3	0,7232	0,7231	0,7225	9,3054	9,3051	9,3012
	MR=0.6	0,7231	0,7232	0,7230	9,3054	9,3053	9,3040
P=50	MR=0.1	0,7232	0,7231	0,7226	9,3052	9,3044	9,3028
JEN=100	MR=0.3	0,7230	0,7230	0,7229	9,3050	9,3045	9,3034
	MR=0.6	0,7232	0,7232	0,7229	9,3052	9,3053	9,3047

Bahsedildiği gibi, önerilen yöntem literatürde iyi bilinen klasik yöntemlerle sayısal ve görsel olarak karşılaştırılmıştır. Yapılan deneylerde LP ve ADD yöntemleri için ayrışma (decomposition) seviyesi 4 olarak seçilmiş ve ADD için Daubechies 'db4' filtresi kullanılmıştır. RUBS için blok boyutları 8x8 olarak belirlenmiştir. Önerilen yöntem için GA parametreleri; popülasyon büyüklüğü 50, jenerasyon sayısı 100, çaprazlama oranı 0.3, mutasyon oranı 0.3 olacak şekilde seçilmiştir, verilen sonuç 30 bağımsız koşmanın ortalaması alınarak verilmiştir.



Şekil 2. Devre ve Oyuncak arabalar görüntü setleri a-b) kaynak görüntüler c) referans görüntü

Deneylerde yapay olarak üretilmiş *Devre* ve *Oyuncak arabalar* görüntü setleri ile doğal olarak alınmış *Saat* ve *Lab* görüntü setleri kullanılmıştır. Yapay olarak elde edilen *Devre* ve *Oyuncak arabalar* görüntü setleri için referans görüntü bulunmaktadır. Bu nedenle bu görüntüler için referans metrikler kullanılarak da değerlendirme yapılmıştır. Şekil 2’de *Devre* ve *Oyuncak arabalar* görüntü setleri, Şekil 3’de ise *Saat* ve *Lab* görüntü setleri görülmektedir.



Şekil 2. Saat ve Lab görüntü setleri

Bahsedilen yöntemler, Çizelge 2’de objektif metrikler, Çizelge 3’de referans tabanlı metrikler bazında karşılaştırılmıştır. Çizelgelerde her sütun için en iyi değer koyulaştırılarak vurgulanmıştır. Objektif metrik sonuçları incelendiğinde genel olarak önerilen yöntemin klasik metriklerden daha iyi sonuçlar ürettiği gözlenmektedir. Yalnızca *Oyuncak arabalar* görüntü seti için RUBS objektif metrikler açısından en iyi sonuçları üretmiştir. Ancak, referans tabanlı metrikler ve görsel sonuçlar incelendiğinde RUBS yönteminin *oyuncak arabalar* görüntü seti için oldukça fazla hata içeren birleşik bir görüntü ürettiği görülmektedir. Bunun nedeni objektif metriklerin oluşan yapay kenarlardan etkilenerek yüksek değerler üretmesidir. Buradan yola çıkarak referans tabanlı metriklerin insan görsel algısıyla daha fazla uyuştuğunu ileri sürebiliriz.

Çizelge 2. Yöntemlerin objektif metriklerle karşılaştırılması

	Oyuncak Arabalar		Devre		Saat		Lab	
	KTk	BF	KTk	BF	KTk	BF	KTk	BF
Yöntem	0,8181	10,3919	0,7765	8,6118	0,7230	9,3050	0,7478	9,8890
LP	0.7983	10.5033	0.7595	6.8404	0.6876	7.0106	0.7013	8.0634
ADD	0.7657	10.3826	0.7564	6.0029	0.6480	6.1525	0.6692	7.2745
RUBS	0.8220	10.8977	0.7718	8.4740	0.7156	9.1343	0.7442	9.7909

Referans tabanlı metrik sonuçları incelendiğinde ise önerilen yöntemin her iki görüntü seti için de en iyi sonuçları ürettiği gözlenmektedir. Şekil 4’te verilen görsel sonuçlar incelendiğinde görüleceği gibi, *Devre* görüntü seti için tüm yöntemler tatmin edici sonuçlar üretmektedir. *Oyuncak arabalar* görüntüsü için ise objektif metrik bazında en iyi sonucu üreten RUBS yönteminin en kötü görsel sonuçları ürettiği söylenebilir. *Oyuncak arabaların* civarında oluşan yapay kenarlar birleşik görüntüyü oldukça bozmaktadır. ADD yönteminin ürettiği birleşik görüntüde de arabaların civarında bozulmalar meydana gelmiştir. Önerilen yöntemin oldukça iyi bir sonuç ürettiği görülebilir. Yine Laplacian yöntemi de başarılı sonuç üretmiştir ki bu sonuç referans tabanlı metrik sonuçları ile tamamen uyuşmaktadır.

Çizelge 3. Yöntemlerin referans tabanlı metriklerle karşılaştırılması

	Oyuncak Arabalar		Devre	
	PSNR	YB	PSNR	YB
Yöntem	164,6906	0,9999	100,4457	0,9981
LP	106.4745	0.9969	88.1407	0.9953
ADD	74.3746	0.9820	89.0363	0.9950
RUBS	78.3060	0.9599	89.5844	0.9943

Gerçek görüntü setlerinden *Lab* görüntü seti için kaymaya bağımlı olan ADD yönteminin oldukça kötü bir sonuç ürettiği açıkça görülmektedir. Bu durumun nedeni *Lab* görüntü setinde her iki görüntü arasında öğrencinin başını bir miktar hareket ettirmesi yani görüntülerin özdeş olmamasıdır. Bu nedenle görüntülerdeki kaymalardan etkilenen ADD yöntemi hatalı sonuç üretmektedir. Buna karşın önerilen yöntemde herhangi bir bozulma görülmemektedir. Son olarak *Saat* birleşik görüntüleri incelendiğinde, önerilen yöntemin diğer yöntemlerden oldukça iyi sonuçlar ürettiği görülecektir. Özellikle RUBS yöntemi net bölgeleri belirlemek için kareler kullandığından ve saat görüntüsünde saat pimi gibi küçük boyutlu objeler bulunduğundan, bu ayrıntılar tespit edilmemektedir. Ayrıca dönüşüm tabanlı yöntemler olan Laplacian ve ADD yöntemlerinin de saat civarında (özellikle pim ve kordon) hatalar yaptığı ancak önerilen yöntemin herhangi bir hata yapmadan birleşik görüntüyü oluşturduğu görülmektedir.


6. TARTIŞMA VE SONUÇ

Bu makalede yeni bir piksel tabanlı çoklu-odaklı görüntü birleştirme yöntemi sunulmaktadır. Önerilen yöntem kaynak görüntülere ait noktasal dağılım fonksiyonlarının (NDF) dağılım parametrelerini (σ) genetik algoritma (GA) kullanarak araştırmaktadır. Elde edilen noktasal dağılım fonksiyonları kullanılarak kaynak görüntüler yapay olarak bulanıklaştırılmakta ve son olarak, üretilen bu yapay görüntüler ve kaynak görüntüler kullanılarak görüntülerdeki net pikseller belirlenmektedir. Sonuçta, birleşik görüntü tespit edilen net piksellerin taşınmasıyla üretilmektedir.

Önerilen yöntem, gerçek ve yapay görüntü setleri üzerinde denenmiş ve yapılan deneylerde klasik yöntemlerle kıyaslanmıştır. Sayısal ve görsel değerlendirmelerde klasik yöntemlerden daha iyi sonuçlar verdiği tespit edilmiştir.

Acknowledgments / Teşekkür

Bu çalışma 110E058 kodlu proje ile TÜBİTAK tarafından desteklenmektedir.



Şekil 3. Görsel sonuçlar

KAYNAKLAR / REFERENCES

- [1] S. Li and B. Yang, "Multifocus image fusion using region segmentation and spatial frequency," *Image and Vision Computing*, vol. 26, pp. 971-979, 2008.
- [2] V. Aslantaş and D. T. Pham, "Depth from automatic defocusing," *Optics Express*, vol. 15, pp. 1011-1023, 2007.
- [3] P. Gemma, "A general framework for multiresolution image fusion: from pixels to regions," *Information Fusion*, vol. 4, pp. 259-280, 2003.
- [4] M. Subbarao, et al., "Focused image recovery from two defocused images recorded with different camera settings," *IEEE Transactions on Image Processing*, vol. 4, pp. 1613-1628, 1995.
- [5] V. Aslantaş and R. Kurban, "Fusion of multi-focus images using differential evolution algorithm," *Expert System Applications*, vol. 37, pp. 8861-8870, Dec 2010.
- [6] P. J. Burt and E. H. Adelson, "The laplacian pyramid as a compact image code," *IEEE Transactions on Communications*, vol. 31, pp. 532-540, 1983.

- [7] P. J. Burt and R. J. Kolczynski, "Enhanced image capture through fusion," in *Computer Vision, 1993. Proceedings., Fourth International Conference on, 1993*, pp. 173-182.
- [8] A. Toet, "A Morphological Pyramidal Image Decomposition," *Pattern Recognition Letters*, vol. 9, pp. 255-261, May 1989.
- [9] G. Pajares and J. M. de la Cruz, "A wavelet-based image fusion tutorial," *Pattern Recognition*, vol. 37, pp. 1855-1872, Sep 2004.
- [10] M. Beaulieu, et al., "Multi- spectral image resolution refinement using stationary wavelet transform," in *Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International, 2003*, pp. 4032-4034 vol.6.
- [11] V. Aslantas and R. Kurban, "A comparison of criterion functions for fusion of multi-focus noisy images," *Optics Communications*, vol. 282, pp. 3231-3242, Aug 2009.
- [12] S. Li, et al., "Combination of images with diverse focuses using the spatial frequency," *Information Fusion*, vol. 2, pp. 169-176, 2001.
- [13] V. Aslantas, et al., "Sınırlı Alan Derinliğini Artırmak İçin Genetik Algoritmaya Dayalı Yeni Bir Yöntem," ASYU, Trabzon, 2012.
- [14] J. H. Holland, *Adaptation in Natural and Artificial Systems: University of Michigan Press, 1975.*
- [15] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning: Addison-Wesley Longman Publishing Co., Inc., 1989.*
- [16] D. Karaboğa, *Yapay zeka optimizasyon algoritmaları: Atlas, 2004.*
- [17] V. Aslantas, "A depth estimation algorithm with a single image," *Optics Express*, vol. 15, pp. 5024-5029, 2007.
- [18] Z. Wang, et al., "Image quality assessment: From error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, pp. 600-612, Apr 2004.
- [19] T. Stathaki, *Image Fusion: Algorithms and Applications: Academic Press, 2008.*
- [20] C. S. Xydeas and V. Petrovic, "Objective image fusion performance measure," *Electronics Letters*, vol. 36, pp. 308-309, Feb 2000.

Makine Mühendisliđi Makalesi
/
Mechanical Engineering Article