

## ODAKLAMA DERİNLİĞİNİN ARTIRILMASINDA DERİN ÖZELLİKLERİN ODAKLAMA DEĞERLERİNİN ÇIKARILMASINDAKİ ETKİLERİNİN İNCELENMESİ

Sibel DANIŞMAZ<sup>1</sup>, Sümeyye Nur EMİR<sup>2</sup>, Hülya DOĞAN<sup>3\*</sup>, Ramazan Özgür DOĞAN<sup>4</sup>

<sup>1</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü,  
ORCID No : <https://orcid.org/0000-0001-6945-6493>

<sup>2</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü,  
ORCID No : <https://orcid.org/0000-0002-7331-2406>

<sup>3</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü,  
ORCID No : <https://orcid.org/0000-0003-3695-8539>

<sup>4</sup>Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Yazılım Mühendisliği Bölümü,  
ORCID No : <https://orcid.org/0000-0003-3695-8539>

Anahtar Kelimeler	Öz
Odaklama derinliği Odaklama derinliğinin artırılması Derin öğrenme Odaklama ölçüm operatörü	<i>Mikroskobik sistemlerde var olan odaklama derinliğinden dolayı numunenin tüm alanının odaklandığı görüntü elde etmek imkânsız olabilmektedir. Bu durum, mikroskobik sistemlerde görüntü işleme ve yapay zekâ algoritmaları kullanılarak gerçekleştirilen sınıflandırma, bölütleme, hizalama (registration), panoramik birleştirme (stitching) gibi uygulamalarının başarılarını olumsuz yönde etkilemektedir. Literatürde numunenin tüm alanının odaklandığı görüntüyü elde etmek için odaklama derinliğinin artırılması yaklaşımları geliştirilmektedir. Literatür çalışmaları, bu yaklaşımların, görüntülerdeki eğrilerin ve kenarların düşük kesinlikte karakterizasyonu, daha yüksek koşma süresi ve incelenen numuneye ve kullanılan mikroskoba göre performans değişimi gibi çeşitli kısıtlamalara sahip olduklarını ortaya koymaktadır. Ek olarak, bu yaklaşımlar odaklama bilgilerini genelde görüntülerin gri seviye değerlerini kullanarak hesaplamaktadırlar. Bu çalışmada bu kısıtlamaları minimize etmek için yeni bir odaklama derinliğinin artırılması yaklaşımı geliştirilmekte ve odaklama derinliğinin artırılmasında derin özelliklerin odaklama değerlerinin çıkarılmasındaki etkileri incelenmektedir. Çalışmada elde edilen sonuçlar derin özelliklerin piksellerin odaklama değerlerini hesaplamada gri seviye değerlerine göre daha etkin olduğunu göstermektedir.</i>

## INVESTIGATION OF EFFECTS OF DEEP FEATURES ON FOCUS VALUES EXTRACTION IN EXTENDED DEPTH OF FOCUS

Keywords	Abstract
Depth of focus Extended depth of focus Deep learning Focus measurement operator	<i>Due to the focusing depth in microscopic systems, it may be impossible to obtain an image in which the entire area of the sample is focused. This situation negatively affects the success of applications such as classification, segmentation, registration, panoramic stitching, which are performed using image processing and artificial intelligence algorithms in microscopic systems. In the literature, approaches are developed to increase the focusing depth to obtain an image in which the entire area of the sample is focused. Literature studies reveal that these approaches have several limitations, such as low-precision characterization of curves and edges in images, higher running time, and performance variation according to the sample examined and the microscope used. In addition, these approaches often calculate focusing information using the gray level values of the images. In this study, a new approach to increasing the focusing depth is developed in order to minimize these limitations and the effects of deep features on the extraction of focusing values in increasing the focusing depth are examined. The results obtained in the study show that the deep features are more effective in calculating the focusing values of the pixels than the gray level values.</i>

Araştırma Makalesi

Research Article

Başvuru Tarihi : 20.05.2023

Submission Date : 20.05.2023

Kabul Tarihi : 04.11.2023

Accepted Date : 04.11.2023

\* Sorumlu yazar: [hulya@ktu.edu.tr](mailto:hulya@ktu.edu.tr)  
<https://doi.org/10.31796/ogummf.1299670>



Bu eser, Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>) hükümlerine göre açık erişimli bir makaledir.

This is an open access article under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

## 1. Giriş

Mikroskobik sistemlerde görüntüleme ekipmanı sabitken numune tablasının odak kaybı olmadan hareket ettiği, aksenal aralık olarak tanımlanan odaklama derinliği mevcuttur. Numune boyutu mikroskobun odaklama derinliğinden daha geniş olduğu durumda, numunenin tüm alanının odaklandığı bir görüntü yakalamak imkânsız olmaktadır. Odaklama derinliği dışında kalan numune alanları bulanık görünmektedir. Araştırmacılar mikroskobik sistemlerde görüntü işleme ve yapay zekâ algoritmaları kullanarak gerçekleştirilen sınıflandırma, bölütleme, hizalama (registration), panoramik birleştirme (stitching) gibi uygulamaları geliştirirken, numune boyutunun odaklama derinliğinden daha geniş olduğu durumlarda yakalanan görüntüyü (bölgesel bulanıklıklara sahip) tercih etmemektedirler. Mikroskobik sistemlerde görüntü işleme ve yapay zekâ algoritmalarının etkinliğini artırmak için odaklama derinliğinin artırılması ile numunenin tüm alanının odaklandığı (optimum odaklı) görüntü oluşturulmaktadır.

Literatürde odaklama derinliğinin artırılması için geliştirilen yaklaşımlar wavefront kodlama ve imge füzyonu tabanlı olmak üzere iki kategoriye ayrılmaktadır (Ambikumar ve diğ., 2016). Wavefront kodlama tabanlı yaklaşımlarda mikroskop objektifinin arka odaklama düzlemine elemanlar yerleştirilerek odaklama derinliği artırılmaktadır (Dowski ve Cathey, 1995). Avantajları: mükemmel hassasiyet ve gerçek zamanlı performans. Dezavantajları: yüksek maliyet ve ek donanım gerektirmesi (Akpınar ve diğ., 2021; Mo ve diğ., 2019; Cohen ve diğ., 2014). İmge füzyonu tabanlı yaklaşımlar ise odaklama derinliğinin artırılması sürecinde farklı bölgeleri odaklanmış görüntü serisi kullanarak optimum odaklı görüntüyü oluşturmaktadır. Literatür araştırmalarına göre imge füzyonu tabanlı yaklaşımlar, mikroskop sistemlerinde numunenin tüm alanının odaklandığı görüntünün üretilmesi (odaklama derinliğinin artırılması) için en sık tercih edilenlerdir (Mo ve diğ., 2019; Hermessi ve diğ., 2021). Avantajları: Düşük maliyetli ve ek donanım gerektirmemesi. Dezavantajları: İncelenen numune ve kullanılan mikroskop çeşidine (ışıklı, floresan, konfokal) göre performans değişimi. İmge füzyonu tabanlı yaklaşımlar üç temel aşamadan oluşmaktadır:

1. Farklı bölgeleri odaklanmış görüntü serisinin oluşturması: Bu aşamada mikroskobun tablası Z ekseninde hareket ettirilerek birden fazla sayıda, aynı perspektif ve farklı odaklamalara sahip görüntüler elde edilmektedir.
2. Görüntü serisindeki piksellerin odaklama değerlerinin hesaplanması: Bu aşamada, her bir pikselin odaklama bilgisi hakkında bilgi veren değerler, odaklama ölçüm operatörleri kullanılarak hesaplanmaktadır. Literatürde

odaklama ölçüm operatörlerini altı sınıfa ayrılmaktadır:

- Gradyan tabanlı: Bu operatörler, odaklama değerlerini belirlemek için piksellerin birinci derece türevlerini kullanmaktadırlar. Gauss Türevi, Tenengrad ve Gradyan Enerjisi literatürde sıklıkla kullanılan gradyan tabanlı operatörlere bazı örneklerdir.

- Laplacian tabanlı: Bu operatörler, odaklama değerlerini çıkarmak için piksellerin ikinci derece türevlerini kullanmaktadırlar. Laplacian Varyansı, Laplacian Enerjisi ve 3B Laplacian bu ölçüm operatörlerine örnek olarak verilebilmektedirler.

- Dalgacık dönüşümü tabanlı: Bu operatörler, piksellerin odaklama değerlerini hesaplamak için ayrık dalgacık dönüşümü katsayılarını kullanmaktadırlar. Dalgacık Katsayısı Toplamı ve Dalgacık Katsayısı Varyansı bu ölçüm operatörlerinin literatürde kullanılan bazı örnekleridir.

- İstatistik tabanlı: Bu operatörler, piksellerin odaklama değerlerini belirlemek için görüntünün yoğunluk ve histogram gibi verilerini kullanmaktadırlar. Chebyshev Momentleri, Öz Değerler, Varyans ve Histogram Entropisi popüler istatistik tabanlı ölçüm operatörlerindedir.

- Kosinüs dönüşümü tabanlı: Bu operatörler, piksellerin odaklama seviyelerini hesaplamak için ayrık kosinüs dönüşümünü kullanmaktadırlar. Literatürde yaygın olarak kullanılan kosinüs dönüşümü tabanlı ölçüm operatörleri Ayrık Kosinüs Dönüşümü Azaltılmış Enerji Oranı ve Ayrık Kosinüs Dönüşümü Enerji Oranı'dır.

- Diğer operatörler: Bu operatörler, odaklama derecelerini hesaplamak için piksellerin belirli özelliklerini kullanmaktadırlar. Yerel İkili Model, Uzamsal Frekans, Ayrık Eğri (Curvelet) Dönüşümü ve Görüntü Eğriliği bu ölçüm operatörlerine örnek olarak verilebilmektedir.

3. Maksimum odaklama değerlerine sahip piksellerin seçilmesi: Bu aşamada, görüntü serisinde maksimum odaklama değerlerine sahip pikseller seçilerek tek bir görüntüde birleştirilmektedir. Araştırmacılar, maksimum odaklama değerine sahip pikselleri belirlemek için füzyon seçim kurallarını kullanmaktadırlar. Klasik füzyon seçim kurallarına örnek olarak Ortalama ve Maksimum Seçme verilebilmektedir.

Bu çalışmanın genel yapısı şu şekilde tasarlanmıştır. Bölüm 2'de odaklama derinliğinin artırılması için

geliştirilen çalışmaların genel literatür taraması verilmektedir. Bölüm 3'te çalışmada önerilen danışmansız öğrenme tabanlı odaklama derinliğinin artırılması yaklaşımı detaylı şekilde anlatılmaktadır. Bölüm 4'te çalışmada elde edilen bulgular verilmektedir. Bölüm 5'te elde edilen bulgular hakkında genel tartışma gerçekleştirilmektedir. Çalışmamızın son kısmı olan Bölüm 6'da ise çalışmanın sonuçları ve gelecekteki çalışmalar için öneriler verilmektedir.

## 2. Bilimsel Yazın Taraması

Daha önce belirtildiği gibi, odaklama derinliğinin artırılması için geliştirilen yaklaşımlar wavefront kodlama ve imge füzyonu tabanlı olmak üzere iki kategoriye ayrılmaktadır. Wavefront kodlama tabanlı yaklaşım öneren çalışmalara örnekler şu şekilde verilebilmektedir: Dowski ve Cathey (1995) çalışmalarında geniş bir odaklama derinliğine sahip görüntüleme performansı sunan optik-dijital sistem üretmişlerdir. Pan ve diğ. (2008) çalışmalarında odaklama derinliğinin artırılması için kübik faz maskeli wavefront kodlama tabanlı görüntüleme teknolojisi geliştirmişlerdir. Wavefront kodlama tabanlı odaklama derinliğinin artırılması yaklaşımı oluşturmak için Zhao ve diğ. (2013) ticari optik tasarım yazılımına dayalı iki ana optimizasyon tekniği geliştirmişlerdir. Gierlak ve diğ. (2013) wavefront kodlama tabanlı odaklama derinliğinin artırılması yaklaşımı tasarlamak için uzamsal ışık modülatörü kullanmışlardır. Akpınar ve diğ. (2021) çalışmalarında odaklama derinliğinin artırılması için kırınımlı optik eleman ve konvolüsyonel sinir ağı kullanarak wavefront kodlama gerçekleştirmişlerdir. Cao ve diğ. (2017) üniform olmayan spektruma maruz kalırken sistemin performansını artırmak için mikroskop sistemine wavefront kodlama eklenmesini önermişlerdir. Mikroskopik sistemlerde odaklama derinliğinin artırılmasında karşılaşılan kısıtlamaları en aza indirmek için Elmalem ve diğ. (2018) tarafından hesaplamalı görüntüleme tabanlı bir teknik önerilmiştir. Du ve diğ. (2019) mikroskopta açıklığı ve odaklama derinliğini aynı anda artırmak için lensle birleştirilmiş wavefront kodlama tabanlı teknik önermişlerdir. Wei ve diğ. (2019) entegre wavefront kodlama sisteminin görüntüleme özelliklerini gözlemlemek için çeşitli optik sistem yüzeylerine adapte edilmiş faz plakası ile iki alternatif sistem kurmuşlardır. Li ve diğ. (2022) odaklama derinliğinin artırılması için genetik algoritma kullanarak odak dışı tutarlılığı artıran yüksek dereceli polinom faz maskesi önermişlerdir. Bu çalışmalarda wavefront kodlama tabanlı yaklaşımların gerçek zamanlı performans sağlayabildiği ancak yüksek maliyet ve ek donanım gerektirmesi gibi çeşitli kısıtlamaları olduğu dikkat çekmektedir.

Literatür çeşitli odaklama ölçüm operatörleri ve imge füzyonu teknikleri öneren çok sayıda çalışma içermektedir (Hermessi ve diğ., 2021; Tan ve diğ., 2020; Liu ve diğ., 2020). Araştırmacılar özellikle tıbbi görüntüleme (Wang ve diğ., 2020; Jose ve diğ., 2021; Liu ve diğ., 2022) ve uzaktan algılama (Ye ve diğ., 2019; Huang ve diğ., 2022) gibi diğer araştırma alanlarında imge füzyonu için birçok algoritma önermişlerdir. Literatür araştırmalarında numunenin tüm alanının odaklandığı görüntüyü üretmek için mikroskop sistemlerinde en sık tercih edilen yöntemin imge füzyonu tabanlı yaklaşımların olduğu görülmektedir. Ancak maliyeti düşük ve ek ekipman gerektirmeyen bu yaklaşımlarla ilgili sınırlı sayıda çalışma bulunmaktadır. İmge füzyonu tabanlı yaklaşımlara yönelik literatür çalışmaları şu şekilde örneklendirilebilmektedir: Valdecasas ve diğ. (2001) odaklama derinliğinin artırılması için yeni bir yöntem geliştirmişler ve çalışmalarında önerilen yöntem değerlendirmesi ve testi için üç farklı test ve 10 alternatif yöntem kullanmışlardır. Aguet ve diğ. (2008) tarafından parlak alan optik kesit koleksiyonundan numunenin dokusunu ve topografyasını ortaklaşa değerlendiren görüntü oluşturma modeline dayalı bir yaklaşım önerilmiştir. Mikroskopik sistemden elde edilmiş görüntü serisinin odaklama özelliklerini çıkarmak için Forster ve diğ. (2004) karmaşık değerli ayrık dalgacık dönüşümüne (KDADD) dayalı bir yaklaşım geliştirmiştir. Fakat, bu yaklaşımın görüntülerden eğri ve kenar bilgilerinin çıkarılması söz konusu olduğunda bazı kısıtlamaları olduğu kaydedilmiştir. Tessens ve diğ. (2007) bu kısıtlamaları en aza indirmek amacıyla ayrık curvelet dönüşümü (ACD) kullanarak odaklama ölçüm operatörü geliştirmişlerdir. Forster ve Tessens'in bulgularına göre, ayrık dalgacık dönüşümü ve ayrık curvelet dönüşümü tarafından üretilen frekans katsayılarının boyutları, serideki görüntülerinin boyutlarından farklıdır. Bu durum odaklama bilgilerinin giriş görüntülerinden yeterince çıkarılmamasına neden olmaktadır. Dogan ve diğ. (2018) mikroskopik sistemlerde odaklama derinliğinin artırılması için, mevcut çok ölçekli dönüşümlerden (ayrık dalgacık dönüşümü, ayrık curvelet dönüşümü) daha hızlı ve daha iyi seyrek temsile sahip, alt örnekleme shearlant dönüşümüne (AÖSD) dayalı yeni bir yaklaşım önermişlerdir. Alanda görünen her basil odakta olacak şekilde genişletilmiş odaklı bir mikroskop görüntüsü oluşturmak için, Costa ve diğ. (2019) çok odaklı bir görüntü füzyon yöntemi önerilmişlerdir. Piccinini ve diğ. (2012) mikroskopik sistemlerde odaklama derinliğinin artırılması için yeni bir teknik geliştirmişlerdir. Araştırmacılar, en yüksek odaklama değerine sahip pikselleri belirlemek için daha önce değindiğimiz gibi füzyon seçim kurallarını kullanmaktadırlar. Klasik füzyon seçim kurallarına (Ortalama ve Maksimum Seçim) ek olarak, çok ölçekli dönüşümlere dayalı yaklaşımlar öneren son

çalışmalarda (Chen ve diğ., 2020; Li ve diğ., 2020; Ramlal ve diğ., 2019) odaklama özellikleri düşük ve yüksek frekans katsayıları kullanılarak hesaplandığından, bu yaklaşımlara uygun füzyon seçim kuralları da ortaya çıkmıştır.

Bu çalışmada, farklı bölgeleri odaklanmış görüntülerden oluşan seri kullanılarak numunenin tüm alanının odaklandığı görüntü üreten yeni bir odaklama derinliğinin artırılması yaklaşımı geliştirilmekte ve odaklama derinliğinin artırılmasında derin özelliklerin odaklama değerlerinin çıkarılmasındaki etkileri incelenmektedir. Literatürde odaklama derinliğinin artırılması için wavefront kodlama tabanlı yaklaşım öneren pek çok çalışma bulunmaktadır. Ayrıca, özellikle tıbbi görüntüleme ve uzaktan algılama gibi diğer araştırma alanlarında, piksellerin odaklama derecesini hesaplamak için literatürde çeşitli odaklama ölçüm operatörleri ve imge füzyonu teknikleri önerilmiştir. Fakat, daha düşük maliyetli olmalarına ve ek ekipman gerektirmemelerine rağmen, odaklama derinliğinin artırılması için sınırlı sayıda imge füzyonu tabanlı yaklaşımlar gerçekleştirilmiştir. Literatürde Varyans ve Tenengrad gibi klasik operatörleri kullanan odaklama derinliğinin artırılması yaklaşımlarının başarıları oldukça düşüktür. Klasik operatörlerle (Varyans, Tenengrad) karşılaştırıldığında, KDADD, ACD, AÖSD'ye dayalı yeni yaklaşımlar, odaklama derinliğinin artırılması için daha keskin odaklama dereceleri sunmaktadır. Fakat, literatür çalışmaları bu yaklaşımların, görüntülerdeki eğrilerin ve kenarların düşük kesinlikte karakterizasyonu, daha yüksek koşma süresi ve incelenen numuneye ve kullanılan mikroskoba göre performans değişimi gibi çeşitli kısıtlamalara sahip olduklarını ortaya koymaktadır. Ek olarak, bu yaklaşımlar odaklama bilgilerini genelde görüntülerin gri seviye değerlerini kullanarak hesaplamaktadırlar. Derin öğrenmeye dayalı yaklaşımlar diğer araştırma alanlarında (özellikle odaklama ölçüm operatörleri ve imge füzyonu teknikleri) popüler hale gelmesine ve tatmin edici performans sağlamasına rağmen, bu tür yaklaşımlar odaklama derinliğinin artırılması için geliştirilmemiştir. Bunun nedeninin ise derin öğrenme ağını modellemek için farklı bölgeleri odaklanmış görüntü serisinden oluşan kapsamlı bir veri setinin bulunmamasıdır. Bu kısıtlamaların üstesinden gelmek için araştırmamız şu katkıları sağlamaktadır.

- Literatürdeki farklı bölgeleri odaklanmış görüntü serisi içeren veri seti kısıtlamasından dolayı, bu çalışmada danışmansız derin öğrenme tabanlı odaklama derinliğinin artırılması yaklaşımı oluşturulmaktadır. Bu çalışma odaklama derinliğinin artırılması için derin öğrenme yaklaşımlarının kullanıldığı ilk çalışmalardandır.

- Odaklama derinliğinin artırılmasında derin özelliklerin odaklama değerlerinin hesaplanmasındaki etkileri incelenmektedir.
- Odaklama bilgilerini hesaplarken genelde görüntülerin gri seviye değerlerini kullanan literatür çalışmalarına aksine bu çalışma derin özellikleri kullanarak hesaplanmaktadır.

### 3. Yöntem

Bu çalışmada, bilimsel araştırma ve yayın etiğine uyulmuştur. Bu çalışma numunenin tüm alanının odaklandığı tek görüntü üretmek için danışmansız derin öğrenme tabanlı odaklama derinliğinin artırılması yaklaşımı sunmaktadır. Bu yaklaşım derin özelliklerin çıkarımı için ağ tasarımı ve füzyon olmak üzere iki ana aşamadan oluşmaktadır. İlk aşamada, giriş görüntülerinin (farklı bölgeleri odaklanmış görüntüler) derin özelliklerini çıkarmak için bir otomatik kodlayıcı modeli tasarlanmaktadır. Füzyon aşamasında, derin özellikler kullanılarak piksellerin odaklama değerleri hesaplanmakta ve farklı bölgeleri odaklanmış görüntü serisi kullanılarak numunenin tüm alanının odaklandığı tek bir görüntü üretilmektedir. Bu aşamalar hakkındaki detaylar şu şekilde açıklanabilmektedir:

#### 3.1. Derin Özelliklerin Çıkarımı için Ağ Tasarımı Aşamaları

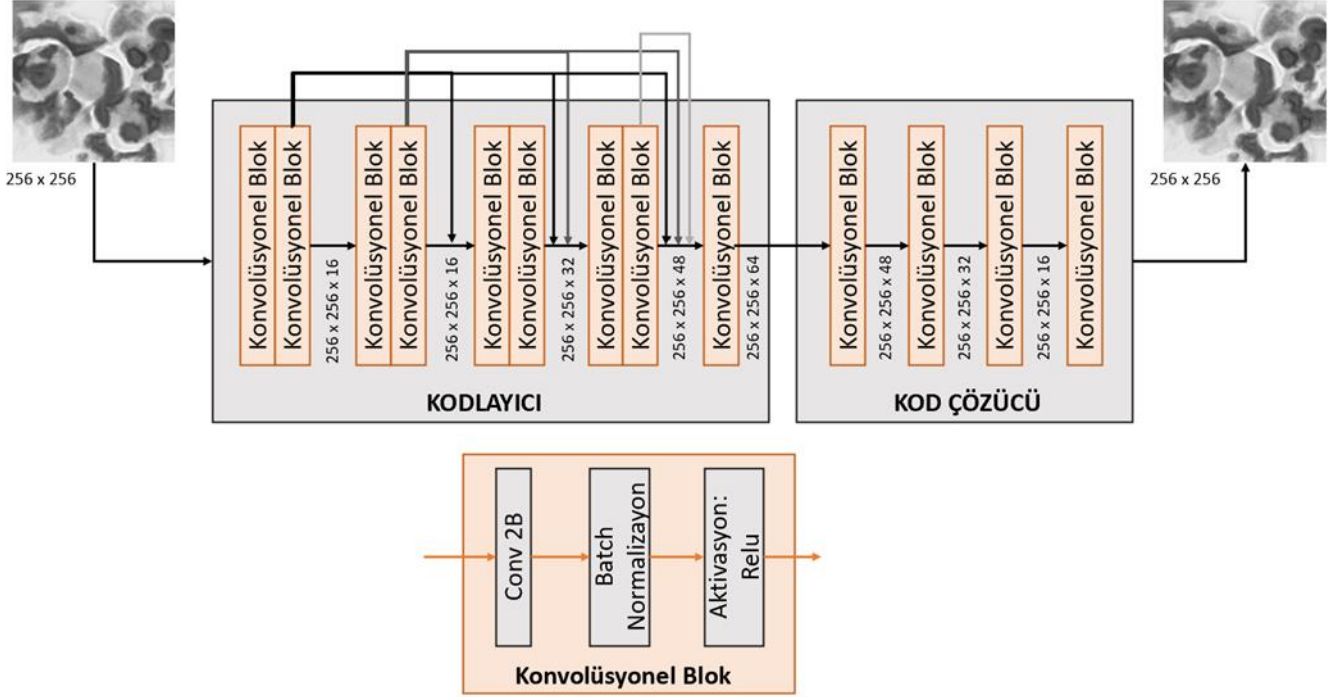
Bu aşamada farklı bölgeleri odaklanmış görüntülerin derin özelliklerini elde etmek için otomatik kodlayıcı modeli oluşturulmaktadır. Derin özelliklerin çıkarılması için oluşturulan otomatik kodlayıcı modelinin yapısı Şekil 1'de gösterilmektedir. Oluşturulan otomatik kodlayıcı modeli bu aşamada eğitilmekte ve modelin eğitilebilir parametreleri sabitlenmektedir. Şekil 1'de gösterildiği gibi, otomatik kodlayıcı modeli kodlayıcı ve kod çözücü olmak üzere iki ana faz içermektedir.

##### 3.1.1. Kodlayıcı

Kodlayıcı fazının birincil önceliği piksellerin odaklama bilgileri hakkındaki özelliklerini elde etmektir. Giriş görüntüleri 256 x 256 boyutuna küçültülerek gri seviyeye çevrildikten sonra bu faz için giriş olarak alınmaktadır. Çıkış olarak toplamda 64 derin özellik matrisi (256 x 256) elde etmektedir. Çıkışları birbirine bağlı olan konvolüsyonel bloklarını içeren 5 bölüm vardır. Konvolüsyonel blok, 3 x 3 filtre boyutu ve 1 stride içeren 1 konvolüsyon katmanı (Conv 2B), 1 batch normalizasyon katmanı ve 1 Relu katmanı içermektedir. Literatür çalışmalarında daha küçük filtre boyutlarının görüntülerden detaylı bilgileri çıkarmak için daha verimli olduğu iddiası nedeniyle, tüm konvolüsyon katmanlarının filtre boyutları 3 x 3 olarak atanmaktadır. Şekil 1'de gösterildiği gibi, konvolüsyonel bloklarının filtre sayıları sırasıyla 16,

16, 32, 48 ve 64'tür. Literatürde odaklama derinliğinin artırılması için gerçekleştirilen çalışmalarda ayrı dalgacık dönüşümü ve ayrı kurvelet dönüşümü tarafından üretilen frekans katsayılarının boyutları (odaklama bilgisi hesaplamak için kullanılan özellik matrisleri), serideki görüntülerinin boyutlarından farklıdır. Piksellerin odaklama bilgileri hesaplanırken bu matrisler yeniden boyutlandırılmaktadır. Bu durum

odaklama bilgilerinin giriş görüntülerinden yeterince çıkarılmamasına neden olmaktadır. Bu kısıtlamayı ortadan kaldırmak için bu çalışmada geliştirilen otomatik kodlayıcı modeli giriş görüntüsü ile aynı boyutta derin özellik matrisleri üretmektedir. Bu nedenle, görüntü boyutunu değiştirmemek için kodlayıcı fazında havuzlama gibi farklı katmanlar kullanılmamaktadır.



Şekil 1. Derin Özelliklerin Çıkarılması için Oluşturulan Otomatik Kodlayıcı Modelinin Yapısı

### 3.1.2. Kod Çözücü

Kod çözücü fazı, kodlayıcı fazında üretilen özellik matrislerini kullanarak giriş görüntüsünü ( $256 \times 256$ ) yeniden oluşturmaktadır. Bu faz derin özellik matrislerini ( $256 \times 256 \times 64$ ) giriş olarak almakta ve çıkış olarak  $256 \times 256$  boyutunda bir görüntü üretmektedir.  $3 \times 3$  filtre boyutu ve 1 stride içeren 1 konvolüsyon katmanı (Conv 2B), 1 batch normalizasyon katmanı ve 1 Relu katmanı içeren 4 konvolüsyonel blok vardır.

### 3.2. Füzyon Aşaması

Füzyon aşaması, farklı bölgeleri odaklanmış görüntü serisi kullanarak numunenin tüm alanının odaklandığı tek bir görüntü üretmektedir. Şekil 2 füzyon aşamasının şematik diyagramını göstermektedir. Şekil 2'de gösterildiği gibi, bu aşama dört temel adımdan oluşmaktadır; (1) Farklı bölgeleri odaklanmış görüntü serisinin oluşturulması, (2) Derin özellik matrislerinin elde edilmesi, (3) Piksellerin odaklama değerlerinin hesaplanması ve (4) Maksimum odaklama değerlerine

sahip piksellerin seçilmesi. Bu adımlar detaylı olarak şu şekilde açıklanabilmektedir:

1. Farklı bölgeleri odaklanmış görüntü serisinin oluşturulması:

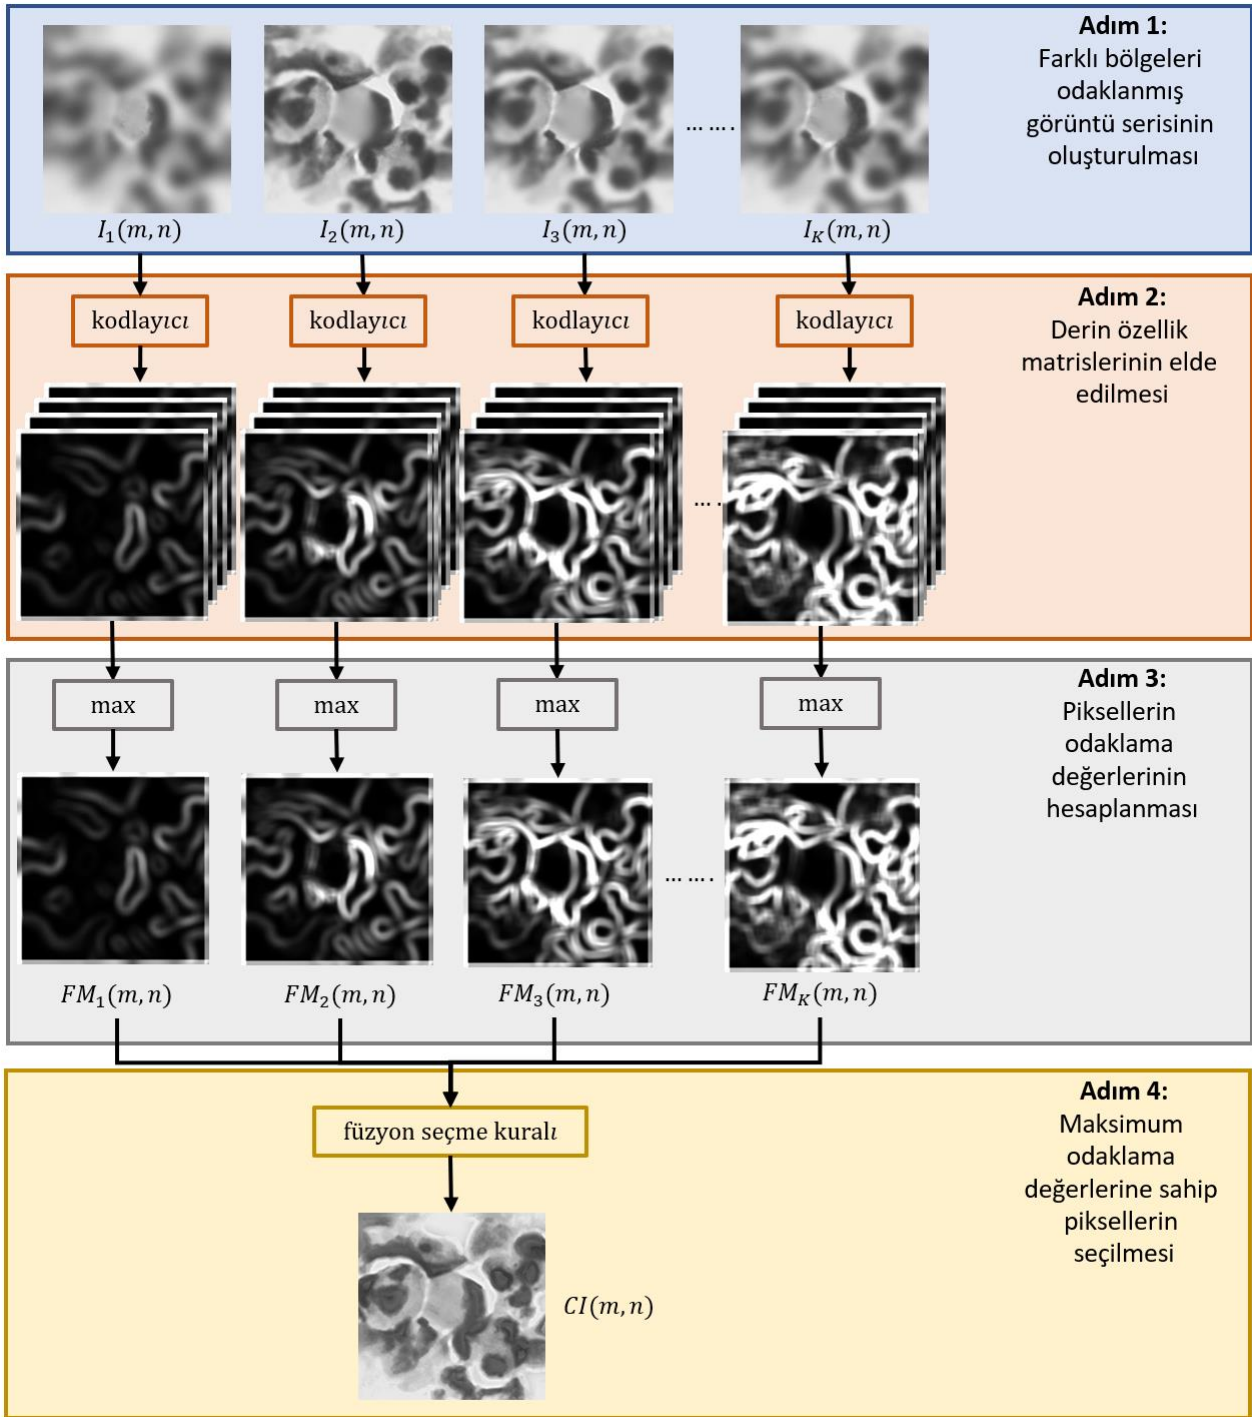
Bu adımda birden fazla sayıda, aynı perspektif ve farklı odaklamalara sahip görüntüler ( $I_1(m, n), I_2(m, n), \dots, I_K(m, n)$ ) elde edilmektedir. Burada  $K$  görüntü sayısını,  $m$  ve  $n$  ise piksel koordinatlarını temsil etmektedir.

2. Derin özellik matrislerinin elde edilmesi:

Bu adımda farklı bölgeleri odaklanmış görüntüler önceki aşamada eğitilmiş otomatik kodlayıcı modeline giriş olarak verilmekte ve kodlayıcı fazından çıkış olarak alınarak her görüntü için 64 tane derin özellik matrisi elde edilmektedir.

3. Piksellerin odaklama değerlerinin hesaplanması:

Odaklama derinliğinin artırılması yaklaşımları farklı bölgeleri odaklanmış görüntüler (giriş görüntüleri) arasında pikselden piksele hizalama gerektirmektedir. Bu durum odaklama bilgilerinin hesaplandığı özellik matrislerinin giriş görüntüleri ile aynı boyutta olması



Şekil 2. Füzyon Aşamasının Şematik Diyagramı; (1) Farklı Bölgeleri Odaklanmış Görüntü Serisinin Oluşturulması, (2) Derin Özellik Matrislerinin Elde Edilmesi, (3) Piksellerin Odaklama Değerlerinin Hesaplanması ve (4) Maksimum Odaklama Değerlerine Sahip Piksellerin Seçilmesi


anlamına gelmektedir. Çok ölçekli dönüşümleri kullanan (KDADD, ACD ve AÖSD) önceki çalışmada giriş görüntüsü ile aynı boyutta özellik matrisleri oluşturulamamaktadır. Bu yüzden pikselden piksele hizalama sağlamak için özellik matrisleri yeniden boyutlandırılmaktadır. Bu durum görüntülerden önemli karakteristik detayların çıkarılmasını imkânsız

hale getirebilmektedir. Bu sorunu çözmek için çalışmada giriş görüntüleri ile aynı boyutlara sahip derin özellik matrisleri kullanılmaktadır. Her giriş görüntüsü için derin özellik matrislerinden maksimum değerler seçilerek piksellerin odaklama ölçüm değerleri ( $FM_1(m, n), FM_2(m, n), \dots, FM_K(m, n)$ ) elde edilmektedir.

#### 4. Maksimum odaklama değerlerine sahip piksellerin seçilmesi:

Dördüncü adımda numunenin tüm alanının odaklandığı tek bir görüntü oluşturmak için füzyon seçme kuralı kullanılmaktadır. Bu adımda kullanılan füzyon seçme kuralı Eşitlik 1 ile tanımlanmaktadır.

$$CI(m, n) = \max(FM(m, n)) \quad (1)$$



Şekil 3. Çalışmada Oluşturulan Serilerdeki Farklı Bölgeleri Odaklanmış Görüntülere Örnekler. Sentetik Görüntü Serisi (a, b, c, d), Mikroskop Görüntü Serisi - 1 (e, f, g, h), Mikroskop Görüntü Serisi - 2 (i, j, k, l)

Çalışmada önerilen odaklama derinliğinin artırılması yaklaşımının etkinliğini değerlendirmek için sentetik ve gerçek mikroskop görüntü serilerini içeren veri seti oluşturulmuştur. Detayları Tablo 1'de verilen serilerdeki farklı bölgeleri odaklanmış görüntülere örnekler Şekil 3'te gösterilmektedir. Sentetik Görüntü Serisi, Pertuz ve diğ. (2013) tarafından oluşturulan simülasyon modeli kullanılarak oluşturulmuştur. Bu seri 50 mm ile 500 mm odaklama mesafesinden elde edilen 30 görüntü içermektedir. Bu serideki her görüntünün boyutu 256 x 256 pikseldir. Görüntülerin elde edilmesi için 3.3 odak uzaklığına sahip kamera kullanılmaktadır. Bu çalışmada kullanılan mikroskop görüntü serileri EPFL Biyomedikal Görüntüleme Grubu (Biomedical Imaging Group -

#### 4. Bulgular

Çalışmada önerilen otomatik kodlayıcı modelinin gerçekleştirilmesi için Intel Core i7-9750 ve 2.60 GHz işlemci, 16 GB RAM ve NVIDIA GeForce RTX 3060 GPU'ya sahip bir PC üzerinde çalışan Python 3.6 yazılımı Keras arka uç Tensorflow'dan oluşan bir cihaz konfigürasyonu kurulmuştur.

<http://bigwww.epfl.ch/demo/edf/index.html>) aracılığıyla oluşturulmaktadır. Mikroskop Görüntü Serisi- 1 için membran etiketleyici boya kullanılarak boyanmış Peyzer yamalarını içeren fare bağırsağı slaytı hazırlanmaktadır (Aguet ve diğ. 2008). Zeiss Plan-Neofluar mikroskopunda 0,75 NA büyütme objektifi kullanılmaktadır. Farklı bölgeleri odaklanmış görüntüler QImaging Retiga CCD kamera kullanılarak elde edilmektedir. Bu seri, boyutu 1996 x 1450 piksel olan 20 renkli görüntü içermektedir. Mikroskop Görüntü Serisi- 2, lazer kaynak etkisi araştırmasından derlenmiştir (Aguet ve diğ. 2008). Bu seri, boyutları 1024 x 768 piksel olan, farklı bölgeleri odaklanmış 13 renkli görüntü içermektedir.

Tablo 1. Veri Seti ve Detayları

Görüntü Serisi	Detayları
Sentetik Görüntü Serisi	30 görüntü, 256 x 256 piksel, 3.3 odak uzaklığına sahip kamera, 50 mm ve 500 mm arasında odaklama mesafesi
Mikroskop Görüntü Serisi- 1	20 görüntü, 1996 x 1450 piksel, Zeiss Plan-Neofluar mikroskop, QImaging Retiga CCD kamera, 0.75 NA büyütme objektifi
Mikroskop Görüntü Serisi- 2	13 görüntü, 1024 x 768 piksel, lazer kaynak etkisi

Sentetik görüntü serisi odaklama derinliğinin artırılması yaklaşımlarının etkinliğini değerlendirmek için kullanılabilir bir referans görüntü içermektedir. Bu nedenle çalışmada sentetik görüntü serisini kullanarak en optimum performansı sağlayan yaklaşımı belirlemek için referans görüntü gerektiren performans analiz metrikleri tercih edilmektedir. Çalışmada kullanılan referans görüntü gerektiren performans analiz metrikleri aşağıdaki gibidir:

#### 1. Kök Ortalama Kare Hatası (Root Mean Squared Error - RMSE)

RMSE, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntü ile referans görüntü arasındaki benzerliği tanımlamaktadır. İdeal yaklaşımla oluşturulan görüntünün RMSE değerinin diğer yaklaşımlara göre daha küçük olması beklenmektedir. RMSE'nin hesaplanması şu şekilde verilmektedir:

$$RMSE = \sqrt{\frac{1}{K \cdot L} \sum_{i=0}^K \sum_{j=0}^L (RI_{i,j} - CI_{i,j})^2} \quad (2)$$

Eşitlik 2'de  $CI$  ve  $RI$ , odaklama derinliğinin artırılması ile oluşturulan görüntüyü ve referans görüntüyü,  $K$  ve  $L$  ise görüntülerin boyutlarını ifade etmektedir.

#### 2. Tepe Sinyal Gürültü Oranı (Peak Signal Noise Ratio - PSNR)

PSNR, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntü ile referans görüntü arasındaki ilişkiyi temsil eden bir ölçüdür. İdeal yaklaşımla oluşturulan görüntünün PSNR değerinin diğer yaklaşımlara göre daha yüksek olması beklenmektedir. PSNR ölçüsü şu şekilde hesaplanmaktadır:

$$PSNR = 20 * \log_{10} \frac{H^2}{\sqrt{\frac{1}{K \cdot L} \sum_{i=0}^K \sum_{j=0}^L (RI_{i,j} - CI_{i,j})^2}} \quad (3)$$

Eşitlik 3'te  $CI$  ve  $RI$ , odaklama derinliğinin artırılması ile oluşturulan görüntüyü ve referans görüntüyü,  $H$  oluşturulan görüntüdeki ( $CI$ ) maksimum değeri,  $K$  ve  $L$  ise görüntülerin boyutlarını temsil etmektedir.

#### 3. Evrensel Kalite Endeksi (Universal Quality Index - UQI)

UQI, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntü ile referans görüntü arasındaki bozukluğu ölçmek için kullanılmaktadır. Görüntünün UQI değerinin 1'e yakın olması yaklaşımın ideal olduğunu göstermektedir. UQI ölçüsü şu şekilde hesaplanmaktadır:

$$UQI = \frac{4\sigma_{RI,CI}\overline{RICI}}{(\sigma_{RI}^2 + \sigma_{RCI}^2)(\overline{RI}^2 + \overline{CI}^2)} \quad (4)$$

Eşitlik 4'te  $CI$  ve  $RI$ , odaklama derinliğinin artırılması ile oluşturulan görüntüyü ve referans görüntüyü,  $\overline{CI}$  ve  $\overline{RI}$  odaklama derinliğinin artırılması ile oluşturulan görüntü ve referans görüntü değerlerinin ortalamalarını,  $\sigma_{RI,CI}$ ,  $\sigma_{RI}$  ve  $\sigma_{CI}$  odaklama derinliğinin artırılması ile oluşturulan görüntü ve referans görüntü değerlerinin varyans ve kovaryansını göstermektedir.

#### 4. Korelasyon Katsayısı (Correlation Coefficient - CC)

CC, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntü ile referans görüntü arasındaki ilişki hakkında bir değer vermektedir. İdeal yaklaşımla oluşturulan görüntünün CC değerinin diğer yaklaşımlara göre daha yüksek olması beklenmektedir. CC değerinin hesaplanması şu şekilde verilmektedir:

$$CC = \frac{\sum_i \sum_j (RI_{i,j} - \overline{RI})(CI_{i,j} - \overline{CI})}{\sqrt{(\sum_i \sum_j (RI_{i,j} - \overline{RI})^2)(\sum_i \sum_j (CI_{i,j} - \overline{CI})^2)}} \quad (5)$$

Eşitlik 5'te  $CI$  ve  $RI$ , odaklama derinliğinin artırılması ile oluşturulan görüntüyü ve referans görüntüyü,  $\overline{CI}$  ve  $\overline{RI}$  odaklama derinliğinin artırılması ile oluşturulan görüntü ve referans görüntü değerlerinin ortalamalarını ifade etmektedir.

Sentetik görüntü serisine ek olarak, odaklama derinliğinin artırılması yaklaşımlarının etkinliğini değerlendirmek için çalışmada iki farklı mikroskop görüntü serisi kullanılmaktadır. Mikroskopik sistemlerde referans olarak kabul edilebilecek herhangi görüntü (tüm alanı odaklanmış) mevcut olmadığından, Mikroskop Görüntü Serisi- 1 ve 2 için hangi yaklaşımın daha performanslı olduğunu belirlemede referans görüntü gerektirmeyen performans analiz metrikleri kullanılmaktadır. Çalışmada kullanılan referans



görüntü gerektirmeyen performans analiz metrikleri hakkındaki detaylar şu şekildedir:

### 1. Bulanıklık Metriği (Blur Metric - BM)

BM, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntüdeki bulanıklık hakkında değer sağlayan metriktir (Crete ve diğ. 2007). İdeal yaklaşımla oluşturulan görüntünün BM değerinin diğer yaklaşımlara göre daha düşük olması beklenmektedir.

### 2. Kurtosis Metriği (KM)

KM, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntünün monotonluğu hakkında bir ölçüm değeri vermektedir. İdeal yaklaşımla oluşturulan görüntünün KM değerinin diğer yaklaşımlara göre daha düşük olması beklenmektedir. KM ölçüsü şu şekilde verilmektedir:

$$KM = \frac{\frac{1}{KL} \sum_i^K \sum_j^L (c_{i,j} - \bar{CI})^4}{(\frac{1}{KL} \sum_i^K \sum_j^L (c_{i,j} - \bar{CI})^2)^2} \quad (6)$$

Eşitlik 6'da  $CI$ , odaklama derinliğinin artırılması ile oluşturulan görüntüyü,  $\bar{CI}$  odaklama derinliğinin artırılması ile oluşturulan görüntü değerlerinin ortalamasını,  $K$  ve  $L$  ise piksel koordinatlarını ifade etmektedir.

### 3. N Görüntü için Evrensel Kalite Endeksinin Genişletilmesi (Extension of Universal Quality Index for N Images - UQIN)

UQIN, odaklama derinliğinin artırılması yaklaşımı ile oluşturulan görüntüye farklı bölgeleri odaklanmış görüntülerden aktarılan veriler hakkında bir değer elde edilmesi için kullanılmaktadır. İdeal yaklaşımla oluşturulan görüntünün UQIN değerinin diğer yaklaşımlara göre daha yüksek olması beklenmektedir. UQIN ölçüsü şu şekilde hesaplanmaktadır:

$$UIQN(I_1, I_2, \dots, I_N, CI) = \frac{1}{T} \sum_{\omega \in T} \sum_{k=1}^N \lambda_{I_k}(\omega) \times UQI(I_k, CI|\omega) \quad (7)$$

$$\lambda_{I_k} = \frac{Y(I_k|\omega)}{\sum_{k=1}^N Y(I_k|\omega)} \quad (8)$$

Eşitlik 7 ve 8'de  $I_1, I_2, \dots, I_N$  farklı bölgeleri odaklanmış görüntüleri,  $CI$  odaklama derinliğinin artırılması ile oluşturulan görüntüyü,  $\omega$  görüntünün alt bir bölgesini,  $Y(I_k|\omega)$  ise alt görüntünün varyansını ifade etmektedir.

Çalışmanın ilk aşamasında, farklı bölgeleri odaklanmış görüntülerin belirgin özelliklerini çıkarmak için Bölüm 3'te ayrıntıları verilen bir otomatik kodlayıcı modeli kurulmaktadır. Çalışmada geliştirilen odaklama derinliğinin artırılması yaklaşımı 150 odaklanmış görüntü kullanılarak eğitilmektedir. Bu model eğitildikten sonra parametreleri sabitlenmekte ve ikinci (füzyon) aşamada görüntüleri birleştirmek için kullanılmaktadır. Batch size ve epoch sayıları sırasıyla 48 ve 40 olarak atanmaktadır. Her epoch, bu aşamanın eğitimi ve doğrulanması için 110 ve 40 görüntü kullanılmaktadır. Her giriş görüntüsünün boyutu 256 x 256 piksele ölçeklenmekte ve gri seviyeye dönüştürülmektedir.

Çalışmada önerilen odaklama derinliğinin artırılması yaklaşımının etkinliğini değerlendirmek ve odaklama derinliğinin artırılmasında derin özelliklerin odaklama değerlerinin çıkarılmasındaki etkilerini incelemek Tablo 1'de detayları verilen görüntü serilerine 5 farklı kategoriden seçilmiş toplam 10 odaklama derinliğinin artırılması yaklaşımı uygulanmaktadır. Tablo 2 - 4 tüm görüntü serileri için odaklama derinliğinin artırılması yaklaşımlarıyla elde edilen performans analiz metriklerinin niceliksel sonuçlarını göstermektedir.

Tablo 2. Sentetik Görüntü Serisi için Odaklama Derinliğinin Artırılması Yaklaşımlarıyla Elde Edilen Performans Analiz Metriklerinin Niceliksel Sonuçları


Kategori	Yaklaşım	RMSE	PSNR	UQI	CC
Gradyan	Gauss Türevi	2.3253	33.2116	0.9716	0.9711
	Tenengrad	2.2281	33.6631	0.9753	0.9744
Laplacian	Laplacian Enerjisi	2.6983	32.0665	0.9660	0.9463
	Diagonal Laplacian	2.5672	32.2112	0.9672	0.9508
Dalgacık	KDADD	2.1675	33.5110	0.9746	0.9734
İstatistik	Varyans	2.4208	32.8588	0.9680	0.9672
	Değiştirilmiş Varyans	2.4375	32.7940	0.9676	0.9550
Diğer	Uzaysal Frekans	2.4954	32.7967	0.9554	0.9560
	ACD	2.0278	33.9026	0.9801	0.9811
	AÖSD	1.9112	34.8010	0.9824	0.9831
<b>Önerilen</b>	<b>Otomatik Kodlayıcı</b>	<b>1.5183</b>	<b>36.4008</b>	<b>0.9987</b>	<b>0.9987</b>

Tablo 3. Mikroskop Görüntü Serisi- 1 için Odaklama Derinliğinin Artırılması Yaklaşımlarıyla Elde Edilen Performans Analiz Metriklerinin Niceliksel Sonuçları


Kategori	Yaklaşım	RMSE	PSNR	UQI	CC
Gradyan	Gauss Türevi	0.4111	0.1972	0.2415	0.4111
	Tenengrad	0.4018	0.1873	0.2474	0.4018
Laplacian	Laplacian Enerjisi	0.4120	0.2044	0.2355	0.4120
	Diagonal Laplacian	0.4232	0.2155	0.2340	0.4232
Dalgacık	KDADD	0.3811	0.1809	0.2504	0.3811
İstatistik	Varyans	0.4198	0.2090	0.2455	0.4198
	Değiştirilmiş Varyans	0.4187	0.2072	0.2410	0.4187
Diğer	Uzaysal Frekans	0.4018	0.1955	0.2359	0.4018
	ACD	0.3809	0.1674	0.2654	0.3809
	AÖSD	0.3642	0.1442	0.2691	0.3642
<b>Önerilen</b>	<b>Otomatik Kodlayıcı</b>	<b>0.3072</b>	<b>0.1055</b>	<b>0.2944</b>	<b>0.3072</b>

Tablo 4. Mikroskop Görüntü Serisi- 2 için Odaklama Derinliğinin Artırılması Yaklaşımlarıyla Elde Edilen Performans Analiz Metriklerinin Niceliksel Sonuçları


Kategori	Yaklaşım	RMSE	PSNR	UQI	CC
Gradyan	Gauss Türevi	0.3211	0.1140	0.7612	0.3211
	Tenengrad	0.3388	0.1152	0.7750	0.3388
Laplacian	Laplacian Enerjisi	0.3465	0.1155	0.7589	0.3465
	Diagonal Laplacian	0.3376	0.1099	0.7810	0.3376
Dalgacık	KDADD	0.3191	0.1051	0.7995	0.3191
İstatistik	Varyans	0.3400	0.1158	0.7698	0.3400
	Değiştirilmiş Varyans	0.3387	0.1165	0.7612	0.3387
Diğer	Uzaysal Frekans	0.3414	0.1152	0.7663	0.3414
	ACD	0.3108	0.1021	0.8150	0.3108
	AÖSD	0.3052	0.0985	0.8199	0.3052
<b>Önerilen</b>	<b>Otomatik Kodlayıcı</b>	<b>0.2805</b>	<b>0.0844</b>	<b>0.8640</b>	<b>0.2805</b>



Şekil 4. Sentetik Görüntü Serisi için Referans Görüntü (a), Gauss Türevi (b), KDADD (c), ACD (d) ve Önerilen Otomatik Kodlayıcı (e) Tabanlı Odaklama Derinliğinin Artırılması Yaklaşımları ile Elde Edilen Görüntüler



Şekil 5. Mikroskop Görüntü Serisi- 1 için Gauss Türevi (a), KDADD (b), ACD (c), Uzaysal Frekans (d) ve Önerilen Otomatik Kodlayıcı (e) Tabanlı Odaklama Derinliğinin Artırılması Yaklaşımları ile Elde Edilen Görüntüler



Şekil 6. Mikroskop Görüntü Serisi- 2 için Gauss Türevi (a), KDADD (b), ACD (c), Uzaysal Frekans (d) ve Önerilen Otomatik Kodlayıcı (e) Tabanlı Odaklama Derinliğinin Artırılması Yaklaşımları ile Elde Edilen Görüntüler

Sentetik ve mikroskop görüntü serileri için referans görüntü, Gauss Türevi, KDADD, ACD, Uzaysal Frekans ve önerilen Otomatik Kodlayıcı tabanlı odaklama derinliğinin artırılması yaklaşımları ile elde edilen görüntüler Şekil 4 - 6'da gösterilmektedir.

## 5. Tartışma

Daha önce de belirtildiği gibi ideal bir odaklama derinliğinin artırılması yaklaşımının daha yüksek

PSNR, UQI, CC, UQIN ve daha düşük RMSE, BM, KM değerlerine sahip görüntü üretmesi beklenmektedir. Tablo 2 - 4'teki performans analiz metriklerinin sonuçları, önerilen yaklaşımın literatürde odaklama derinliğinin artırılması için geliştirilen en popüler yaklaşımlardan daha iyi performans sağladığını göstermektedir. En yüksek RMSE, BM, KM ve en az PSNR, UQI, CC, UQIN ile gradyan, laplacian ve istatistik tabanlı yaklaşımların en kötü performansı sağlamaları dikkat çekicidir. Farklı bölgeleri odaklanmış

görüntülerden elde edilen derin özelliklerin gri seviye değerlerine göre odaklama bilgilerinin çıkarılmasında daha etkin oldukları görülmektedir.

Şekil 4.a'daki referans görüntü ile odaklama derinliğinin artırılması yaklaşımları ile elde edilmiş görüntüler karşılaştırıldığında, otomatik kodlayıcı tabanlı yaklaşımın daha iyi bir performansa sahip olduğu açıkça görülmektedir. Önerilen odaklama derinliğinin artırılması yaklaşımı ile elde edilen görüntüler daha az bulanıklığa ve gürültü seviyesine sahip olup, referans görüntüye en çok benzeyendir. Danışmansız derin öğrenmenin RMSE, PSNR, UQI, CC, BM, KM ve UQIN açısından tüm görüntü serileri için optimum verimliliği sağladığını gösteren nicel sonuçlar, Şekil 4 - 6'daki öznel görsellerle uyumludur.

Bölüm 2'de belirtildiği gibi, çalışmada önerilen odaklama derinliğinin artırılması yaklaşımının literatüre birçok katkısı mevcuttur. Fakat bu yaklaşım bazı kısıtlamalara da sahiptir. Bu kısıtlamalar şu şekilde özetlenebilmektedir: Odaklama derinliğinin artırılması yaklaşımının uygulanması için bu çalışmada 2,60 GHz hızında çalışan Intel Core i7-9750 işlemcili, 16 GB RAM'li ve 12 GB GPU VRAM'li NVIDIA GeForce RTX 3060 GPU'lu bir bilgisayar içeren bir donanım yapılandırması kullanılmıştır. Görüntü işleme, bilgisayarlı görme ve tıbbi görüntüleme analizinde derin öğrenme ve CNN tabanlı tekniklerin kullanıldığı literatür çalışmaları ile karşılaştırıldığında, GPU'muz daha düşük kapasiteye sahiptir. Bu donanım yapılandırması kısıtlamasını en aza indirmek için giriş görüntüsü boyutunu 256 x 256'ya düşürerek GPU tüketimi optimize edilmiştir. Daha önce de belirtildiği gibi, derin özelliklerden yararlanarak piksellerin odaklama derecelerinin elde edilmesine yönelik odaklama derinliğinin artırılması yaklaşımı sunan ilk çalışmadır. Derin öğrenmeyi ve CNN tabanlı görüntü işleme tekniklerini geliştiren önceki çalışmaların aksine, bu çalışmada farklı odaklamalara sahip görüntülerden yüksek boyutlu öznetelikler elde etmek için temel bir otomatik kodlayıcı modeli oluşturulmuştur. Bu model yalnızca konvolüsyonel bloklarından oluşmaktadır.

## 6. Sonuçlar

Numunenin tüm alanının odaklandığı (optimum odaklı) görüntü üretmek için, bu çalışmada yeni bir odaklama derinliğinin artırılması yaklaşımı geliştirilmektedir. Önerilen yaklaşım derin özelliklerin çıkarımı için ağ tasarımı ve füzyon olmak üzere iki ana aşamadan oluşmaktadır. İlk aşamada farklı bölgeleri odaklanmış görüntülerin belirgin özelliklerini çıkarmak için otomatik kodlayıcı tasarlanmaktadır. Füzyon aşaması farklı bölgeleri odaklanmış görüntü serisini kullanarak numunenin tüm alanının odaklandığı görüntü üretmektedir.

Literatürdeki çalışmalar yeni odaklama derinliği artırılması yaklaşımı önermek yerine, genellikle daha yüksek doğruluk ve daha düşük bulanıklık elde etmek için bir ön veya son işleme algoritması geliştirmektedirler. Bu çalışmada, danışmansız derin öğrenmeye dayalı yeni odaklama derinliği artırılması yaklaşımı önerilmektedir. Literatürdeki çalışmaların aksine, önerilen yaklaşım daha iyi odaklama gösterimi ve daha yüksek performans sunmaktadır. İşlem öncesi veya sonrası bir algoritma gerektirmediğinden, minimum hesaplama maliyeti ve karmaşıklığı vardır. Ayrıca, önerilen yaklaşım piksellerin odaklama bilgilerini hesaplarken yalnızca görüntülerin gri seviye değerlerini kullanan önceki çalışmaların aksine, derin özellikleri kullanmaktadır.

Sentetik ve mikroskop görüntü serilerinden oluşan veri seti, önerdiğimiz yaklaşımın hem nicel hem de nitel analizi için test edilmektedir. Hangi odaklama derinliğinin artırılması yaklaşımının, sentetik görüntü serisi için giriş görüntülerinden daha önemli ayrıntıları çıkarabileceğini belirlemek için, referans gerektiren performans analiz metrikleri olarak RMSE, PSNR, UQI ve CC değerleri kullanılmaktadır. Yüksek performanslı yaklaşımla oluşturulan görüntünün daha düşük RMSE ve daha yüksek PSNR, UQI ve CC değerleri üretmesi beklenmektedir. Sentetik görüntü serisi için performans analiz metriklerinin sonuçları, önerdiğimiz yaklaşımın diğerlerinden daha etkili olduğunu göstermektedir. Çünkü en yüksek PSNR, UQI ve CC ve en düşük RMSE değerlerine sahiptir. Ayrıca görsel bulgular, önerilen yaklaşımın danışmansız derin öğrenme modeli kullanılarak üretilen görüntünün en az bulanıklık ve gürültüye sahip olduğunu ve referans görüntüye en çok benzediğini göstermektedir. Sentetik görüntü serisine ek olarak, hangi odaklama derinliği artırılması yaklaşımının, mikroskop görüntü serileri için giriş görüntülerinden daha önemli ayrıntıları çıkarabileceğini belirlemek için referans gerektirmeyen performans analiz metrikleri olarak BM, KM ve UQIN kullanılmaktadır. Yüksek performansa sahip yaklaşımla oluşturulan görüntünün daha düşük BM, KM ve daha yüksek UQIN değerleri vermesi beklenmektedir. Daha düşük BM ve KM değerlerine ve daha yüksek UQIN değerlerine sahip olan önerdiğimiz yaklaşımın diğer literatür operatörlerinden daha iyi performans gösterdiği açıktır.

## Araştırmacıların Katkısı

Bu araştırmada; Yazar1, anketin tasarımı, uygulanması, bilgisayara ortamına aktarılması, ... ; Yazar2, bilimsel yayın araştırması, makalenin oluşturulması, ... ; Yazar3, istatistiki analizler, makalenin sonuçlar.... hazırlanması konularında katkı sağlamışlardır.

**Çıkar Çatışması**

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

**Kaynaklar**

- Aguet, F., Van De Ville, D. ve Unser, M. (2008). Model-based 2.5-D deconvolution for extended depth of field in brightfield microscopy. *IEEE Transactions on Image Processing*, 17(7), 1144-1153. doi: <https://doi.org/10.1109/TIP.2008.924393>
- Akpinar, U., Sahin, E., Meem, M., Menon, R. ve Gotchev, A. (2021). Learning wavefront coding for extended depth of field imaging. *IEEE transactions on image processing*, 30, 3307-3320. doi: <https://doi.org/10.1109/TIP.2021.3060166>
- Ambikumar, A. S., Bailey, D. G. ve Gupta, G. S. (2016). Extending the depth of field in microscopy: A review. 2016 International Conference on Image and Vision Computing New Zealand (IVCNZ), 1-6.
- Cao, Z., Zhai, C., Li, J., Xian, F. ve Pei, S. (2017). Combination of color coding and wavefront coding for extended depth of field. *Optics Communications*, 392, 252-257. doi: <https://doi.org/10.1016/j.optcom.2017.02.016>
- Chen, J., Li, X., Luo, L., Mei, X. ve Ma, J. (2020). Infrared and visible image fusion based on target-enhanced multiscale transform decomposition. *Information Sciences*, 508, 64-78. doi: <https://doi.org/10.1016/j.ins.2019.08.066>
- Cohen, N., Yang, S., Andalman, A., Broxton, M., Grosenick, L., Deisseroth, K., Horowitz, M. ve Levoy, M. (2014). Enhancing the performance of the light field microscope using wavefront coding. *Optics express*, 22(20), 24817-24839. doi: <https://doi.org/10.1364/OE.22.024817>
- Costa, M. G. F., Pinto, K. M. B., Fujimoto, L. B., Ogusku, M. M. ve Costa Filho, C. F. (2019). Multi-focus image fusion for bacilli images in conventional sputum smear microscopy for tuberculosis. *Biomedical Signal Processing and Control*, 49, 289-297. doi: <https://doi.org/10.1016/j.bspc.2018.12.018>
- Crete, F., Dolmiere, T., Ladret, P. ve Nicolas, M. (2007). The blur effect: perception and estimation with a new no-reference perceptual blur metric. In *Human vision and electronic imaging XII*, 6492, 196-206.
- Dogan, H., Baykal, E., Ekinici, M., Ercin, M. E. ve Ersoz, S. (2018). A novel extended depth of field process based on nonsubsampling shearlet transform by estimating optimal range in microscopic systems. *Optics Communications*, 429, 88-99. doi: <https://doi.org/10.1016/j.optcom.2018.08.006>
- Dowski, E. R. ve Cathey, W. T. (1995). Extended depth of field through wave-front coding. *Applied optics*, 34(11), 1859-1866. doi: <https://doi.org/10.1364/AO.34.001859>
- Du, H., Dong, L., Liu, M., Zhao, Y., Wu, Y., Li, X., Jia, W., Liu X., Hui, M. ve Kong, L. (2019). Increasing aperture and depth of field simultaneously with wavefront coding technology. *Applied Optics*, 58(17), 4746-4752. doi: <https://doi.org/10.1364/AO.58.004746>
- Elmalem, S., Giryas, R. ve Marom, E. (2018). Learned phase coded aperture for the benefit of depth of field extension. *Optics express*, 26(12), 15316-15331. doi: <https://doi.org/10.1364/OE.26.015316>
- Forster, B., Van De Ville, D., Berent, J., Sage, D. ve Unser, M. (2004). Complex wavelets for extended depth-of-field: A new method for the fusion of multichannel microscopy images. *Microscopy research and technique*, 65(1-2), 33-42. doi: <https://doi.org/10.1002/jemt.20092>
- Gierlak, M., Albrecht, S., Kauer, J., Leverenz, E. ve Beckers, I. E. (2013). Wavefront coding using a spatial light modulator for extended depth of field microscopy. In *European Conference on Biomedical Optics*, p. 879803.
- Hermessi, H., Mourali, O. ve Zagrouba, E. (2021). Multimodal medical image fusion review: Theoretical background and recent advances. *Signal Processing*, 183, 108036. doi: <https://doi.org/10.1016/j.sigpro.2021.108036>
- Huang, M., Liu, S., Li, Z., Feng, S., Wu, D., Wu, Y. ve Shu, F. (2022). Remote sensing image fusion algorithm based on two-stream fusion network and residual channel attention mechanism. *Wireless Communications and Mobile Computing*, 2022, 1-14. doi: <https://doi.org/10.1155/2022/8476000>
- Jose, J., Gautam, N., Tiwari, M., Tiwari, T., Suresh, A., Sundararaj, V. ve Rejeesh, M. R. (2021). An image quality enhancement scheme employing adolescent identity search algorithm in the NSST domain for multimodal medical image fusion. *Biomedical Signal Processing and Control*, 66, 102480. doi: <https://doi.org/10.1016/j.bspc.2021.102480>
- Li, L., Si, Y., Wang, L., Jia, Z. ve Ma, H. (2020). A novel approach for multi-focus image fusion based on SF-PAPCNN and ISML in NSST domain. *Multimedia Tools and Applications*, 79, 24303-24328. doi: <https://doi.org/10.1007/s11042-020-09154-4>

- Li, Y., Wang, J., Zhang, X., Hu, K., Ye, L., Gao, M., Cao, Y. ve Xu, M. (2022). Extended depth-of-field infrared imaging with deeply learned wavefront coding. *Optics Express*, 30(22), 40018-40031. doi: <https://doi.org/10.1364/OE.471443>
- Liu, S., Wang, M., Yin, L., Sun, X., Zhang, Y. D. ve Zhao, J. (2022). Two-scale multimodal medical image fusion based on structure preservation. *Frontiers in Computational Neuroscience*, 15, 133. doi: <https://doi.org/10.3389/fncom.2021.803724>
- Liu, Y., Wang, L., Cheng, J., Li, C. ve Chen, X. (2020). Multi-focus image fusion: A survey of the state of the art. *Information Fusion*, 64, 71-91. doi: <https://doi.org/10.1016/j.inffus.2020.06.013>
- Mo, X., Zhang, T., Wang, B., Huang, X., Kuang, C. ve Liu, X. (2019). Alleviating image artifacts in wavefront coding extended depth of field imaging system. *Optics Communications*, 436, 232-238. doi: <https://doi.org/10.1016/j.optcom.2018.12.006>
- Pan, C., Chen, J., Zhang, R. ve Zhuang, S. (2008). Extension ratio of depth of field by wavefront coding method. *Optics express*, 16(17), 13364-13371. doi: <https://doi.org/10.1364/OE.16.013364>
- Pertuz, S., Puig, D. ve Garcia, M. A. (2013). Analysis of focus measure operators for shape-from-focus. *Pattern Recognition*, 46(5), 1415-1432. doi: <https://doi.org/10.1016/j.patcog.2012.11.011>
- Piccinini, F., Tesei, A., Zoli, W. ve Bevilacqua, A. (2012). Extended depth of focus in optical microscopy: Assessment of existing methods and a new proposal. *Microscopy research and technique*, 75(11), 1582-1592. doi: <https://doi.org/10.1002/jemt.22104>
- Ramlal, S. D., Sachdeva, J., Ahuja, C. K. ve Khandelwal, N. (2019). An improved multimodal medical image fusion scheme based on hybrid combination of nonsubsampling contourlet transform and stationary wavelet transform. *International Journal of Imaging Systems and Technology*, 29(2), 146-160. doi: <https://doi.org/10.1002/ima.22310>
- Tan, W., Tiwari, P., Pandey, H. M., Moreira, C. ve Jaiswal, A. K. (2020). Multimodal medical image fusion algorithm in the era of big data. *Neural Computing and Applications*, 1-21. doi: <https://doi.org/10.1007/s00521-020-05173-2>
- Tessens, L., Ledda, A., Pizurica, A. ve Philips, W. (2007). Extending the depth of field in microscopy through curvelet-based frequency-adaptive image fusion. In *2007 IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP'07*, 1, 1-861.
- Valdecasas, A. G., Marshall, D., Becerra, J. M. ve Terrero, J. J. (2001). On the extended depth of focus algorithms for bright field microscopy. *Micron*, 32(6), 559-569. doi: [https://doi.org/10.1016/S0968-4328\(00\)00061-5](https://doi.org/10.1016/S0968-4328(00)00061-5)
- Wang, K., Zheng, M., Wei, H., Qi, G. ve Li, Y. (2020). Multi-modality medical image fusion using convolutional neural network and contrast pyramid. *Sensors*, 20(8), 2169. doi: <https://doi.org/10.3390/s20082169>
- Wei, X., Han, J., Xie, S., Yang, B., Wan, X. ve Zhang, W. (2019). Experimental analysis of a wavefront coding system with a phase plate in different surfaces. *Applied Optics*, 58(33), 9195-9200. doi: <https://doi.org/10.1364/AO.58.009195>
- Ye, F., Li, X. ve Zhang, X. (2019). FusionCNN: a remote sensing image fusion algorithm based on deep convolutional neural networks. *Multimedia Tools and Applications*, 78, 14683-14703. doi: <https://doi.org/10.1007/s11042-018-6850-3>
- Zhao, T., Mauger, T. ve Li, G. (2013). Optimization of wavefront-coded infinity-corrected microscope systems with extended depth of field. *Biomedical optics express*, 4(8), 1464-1471. doi: <https://doi.org/10.1364/BOE.4.001464>