

## ÇOK MODLU GÖRÜNTÜ BİRLEŞTİRMEDE DERİN ÖĞRENME YAKLAŞIMLARI

*Emre BENDEŞ*

*Nevşehir Hacı Bektaş Veli Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği  
Bölümü, Nevşehir / Türkiye*

**Öz:** İnsan gözünün algılayabildiği ışına elektromanyetik spektrumda çok kısıtlı bir alandadır. Bununla birlikte gelişen görüntüleme teknolojileri ile termal ışınlar hatta radyo dalgaları gibi çok farklı elektromanyetik ışınlar algılanıp görselleştirilebilmektedir. Farklı dalga boylarından üretilmiş görseller farklı bilgiler içermekte ve birinde gerçekleşen algılama diğerinde gerçekleşmemektedir. Bunun anlamı oluşacak iki görüntünün birbirini destekleyecek bilgiler içerebileceğidir. Dolayısıyla bu görsellerin insan algısı ya da makine algısını artırabilmek için tek görüntüde birleştirilmesi çok elverişli sonuçlar doğurmaktadır ve bu işlemler son yıllarda dikkat çeken görüntü işleme yöntemleri arasında yer almaktadır. Özellikle medikal, uzay ve uydu görüntüleme, savaş alanı izleme, gizlenmiş silah tespiti, artırılmış gece görüşü gibi birçok alanda görüntü işleme kullanılmaktadır. Bu sebeple görüntüleri analiz edip çok daha anlamlı bir görüntü elde etmeyi amaçlayan birçok görüntü birleştirme tekniği geliştirilmiştir. Diğer yandan geliştirilen yöntemlerin kaynak görüntülerine ve onların içeriklerine bağımlı olması görüntü birleştirme yöntemlerinin problemleri arasındadır. Yapay sinir ağlarının genelleştirme özelliği ile aşılabilecek bu problemler tekniklerin gelişmesi gizli katman sayılarının olgunlaşması ile uygun sonuçlar verebilmeye başlamıştır ve derin öğrenme yöntemleri görüntü birleştirme sahasında yaygın olarak kullanılmaya başlamıştır. Bu çalışmada artan rağbetle birlikte görüntü birleştirme yöntemlerinde de sıklıkla kullanılan derin öğrenmenin seçkin örnekleri ile farklı kalite metrikleri kullanarak kıyaslamalı bir çalışma yürütülmüştür. Yapılan deneysel çalışmalarla yapay sinir ağlarının görüntü birleştirme uygulamalarında sağladığı kazanımlar vurgulanmıştır.

**Anahtar Kelimeler:** Görüntü Birleştirme, Derin Öğrenme, Görüntü İşleme, Kalite Metrikleri

### GİRİŞ

Günümüzde görsel bilgi birçok alanda büyük önem taşımaktadır. Bazen görsel bilgiler insan algısına hitap ederken, bazen de bir sistem için girdi olarak kullanılmaktadır. Ne amaçla kullanılacak olursa olsun görsel veri üzerindeki anlamlı bilgi büyük önem arz etmektedir. Amacına uygun olarak bir görüntünün sağlayabileceği maksimum bilgiyi içermesi üretim, sağlık teknolojileri, askeri uygulamalar, uzay ve havacılık uygulamaları gibi birçok alanda arzu edilen bir sonuç olacaktır. Görüntü birleştirme tam da bu noktada kullanılmakta olup anlamlı bilgilerim maksimum oranda sunulduğu bir görüntü elde edebilmek için farklı kaynaklardan alınan görsel bilgilerin işlenip birleşik görüntüye aktarılması işlemleri olarak tanımlanmaktadır.

Görsel bilgi elektromanyetik spektrumun farklı dalga boylarındaki ışınları yakalayıp sayısallaştıran algılayıcılar vasıtası ile gerçekleşebildiği gibi ultrason da olduğu gibi ses dalgalarının yansımalarının görselleştirilmesi ile de elde edilebilmektedir. Günümüzde görüntüleme teknolojilerinin çeşitliliği görüntü birleştirme açısından iki farklı sonuç doğurmaktadır. Bunlar; 1. Bir sensörden alınan bilgiler algılayıcı yapısı ya da optik sistem sebebi ile bütün sahneyi kapsayıcı görüntüyü tek görüntüde sunmamaktadır, 2. Farklı sensörler aynı sahne için farklı bilgi sağlayacaktır. İlk madde kamera donanımının belirli konfigürasyonlarının (odaklama noktası, pozlama süresi vs.) sahnenin belirli konumu için net ve doğru algılama yaparken diğer kısımlarında elde edilen verilerin yetersiz ya da bozuk bilgi içereceği gerçeği ile alakalıdır. Mesela bir kamera sahnede belirli bir mesafeye odaklanırsa bu mesafenin ilerisindeki ve gerisindeki uzaklıklarda bulunan cisimler bulanık algılanır. Ya da aydınlık ve karanlık bölgeleri içeren bir sahnede

## TAM METİN SÖZEL SUNUMLAR

görüntü karanlık bölgeyi algılayacak şekilde bir pozlama ile çekilirse aydınlık yerler beyaz tersi durumda ise karanlık bölgeler siyah çıkacaktır. Bu hataları ortadan kaldıracak görüntü birleştirme yöntemleri tek tip algılayıcı olması sebebi ile tek modlu görüntü birleştirme olarak isimlendirilmektedir. Çok modlu görüntü birleştirme farklı dalga boylarında birbirini tamamlayıcı nitelikte farklı bilgilerin aynı sahne üzerinden algılanabileceği gerçeği üzerine kurgulanan görüntü birleştirme tekniklerinin genel ismidir. Bu tekniklerde aynı sahne birden fazla farklı algılama yapan kamera sistemi ile görüntülenmektedir. Bu sahada sert ve yumuşak dokuların ayrı ayrı algılandığı CT ve MR görüntülerinin birleştirilmesi ya da farklı dalga boylarındaki uydu görüntülerinin birleştirilmesi örnek verilebilir. Bununla birlikte termal ve görünür bölge görüntülerinin birleştirilmesi savaş alanı gözleme, artırılmış gece görüşü, gizlenmiş silah tespiti gibi uygulamalarda sıklıkla başvurulmaktadır. Bu çalışmada termal ve optik bilgilerin birleştirilmesini amaçlayan çok modlu görüntü birleştirme yöntemleri kullanılmıştır.

Çok modlu görüntü birleştirmede uzaysal ya da dönüşüm tabanlı teknikler günümüze kadar sıklıkla kullanılmıştır. Uzaysal yöntemlerde görüntülerin direk sayısal piksel değerleri kullanılmakta ve bu sayısal değerler üzerine geliştirilen yöntemlerle aynı noktadaki birleşik görüntüye ait piksel değeri hesaplanmaktadır. Bu yöntemler kaynak görüntülerdeki görüntülerden ya da başka problemlerden kolaylıkla etkilenmektedir. Bu yöntemlerin alternatifi olan dönüşüm tabanlı yöntemlerde kaynak görüntüler bir takım sayısal işlemler uygulanarak ayrık dalgacık dönüşümü gibi çok katmanlı dönüşümlere tabi tutulurlar. Birleştirme işlemi bu boyutta gerçekleştirilir ve sonuca ters dönüşüm uygulanarak birleşik görüntü elde edilir.

Her ne kadar dönüşüm tabanlı yöntemlerde bazı ilerlemeler elde edilse de kaynak görüntülerdeki değişimler birleştirme sonucuna direk etki etmekte ve genel bit birleştirme kuralı ortaya koymak oldukça zor bir problemdir. Bu amaçla yapay zekâ tekniklerine sıklıkla başvurulmaktadır (Aslantas, Bendes, Kurban, & Toprak, 2014). Derin öğrenme tekniklerindeki gelişmelerle birlikte bu tekniklerde kendilerini görüntü birleştirme alanında gösterilmiş ve birçok yöntem geliştirilmiştir (Li, Wu, & Kittler, 2018; Li, Wu, & Durrani, 2019; Liu, Chen, Cheng, Peng, & Wang, 2018).

Bu çalışmada derin öğrenmenin görüntü birleştirmeye katkısını göz önüne koymak maksadı ile deneysel kıyaslamalar yapılmış ve geleneksel görüntü birleştirme yöntemlerine göre avantajları dezavantajları gözlemlenmiştir. İkinci bölümde kullanılan teknikler ve metrikler hakkında bilgi verilmiştir.

### BİRLEŞTİRME KURALLARI

Görüntü birleştirme algoritmaları kaynak görüntülerden gelen verileri birleştirirken birleştirme kuralı denilen aritmetik işlemleri kullanırlar. En basit birleştirme kuralı kaynak görüntü bilgilerinin ortalamasını (O) almaktır. Ortalamada sonuç görüntüde kontrastın düşmesi söz konusudur. Diğer bir yöntemde ise maksimum olanı seçme (MS) yaklaşımı kullanılır. Bu yaklaşımda bir görüntüdeki bilgi ihmal edilirken büyük değeri içerek görüntüdeki bilgi olduğu gibi birleşik görüntüye aktarılır. Son yaklaşımda ağırlıklı ortalama (AO) kaynak görüntü verilerine uygulanır. Birleşik görüntüde her biri kendi bağlı büyüklükleri kadar ifade edilecektir. Genel birleştirme kuralı şu şekilde formüle edilebilir:

$$I_f(i, j) = kI_1(i, j) + (1 - k)I_2(i, j) \quad (1)$$

Burada  $I_f(i, j)$  i ve j koordinatlarındaki birleşik görüntü bilgisi  $I_1(i, j)$  ve  $I_2(i, j)$  aynı koordinatlardaki kaynak görüntü bilgisi ve k birleştirme katsayısıdır. Bu katsayının değeri aşağıdaki tabloda birleştirme kuralları için verilmiştir.

# TAM METİN SÖZEL SUNUMLAR

## 1. Birleştirme kuralları için $k$ değerleri

| Birleştirme Kuralı | Kısaltması | $k$ değeri           |
|--------------------|------------|----------------------|
| Ortalama           | O          | 0.5                  |
| Maksimumu seçme    | MS         | 1 ya da 0            |
| Ağırlıklı ortalama | AO         | [0-1] (hesaplanmalı) |

## GÖRÜNTÜ BİRLEŞTİRME TEKNİKLERİ

Bu bölümde deneysel çalışmalarda kullanılmış görüntü birleştirme teknikleri hakkında özet bilgi verilmiştir. Ayrıca Tablo 2’de bütün yöntemler özet olarak sunulmuştur.

Kaynak görüntülerin tek görüntüde toplanılması aslında çok basit bir şekilde kaynak görüntülerin piksel değerlerinin ortalaması alınarak gerçekleştirilebilir. Bu şekilde gerçekleşen bir birleştirmede kaynak görüntülerden hiçbir bilgi kaybolmayacaktır ancak kontrast düşecektir. Basit bir yöntem olmakla birlikte diğer yöntemlerin gelişimini göz önüne sermek için ortalama yöntemi de kıyaslamalarda kullanılmıştır. Kaynak görüntülerin daha iyi analiz edilip daha verimli görüntü birleştirme tekniği için sıklıkla dönüşüm tabanlı yöntemler kullanılır. Laplas piramidi (LP) yöntemi sıklıkla rastlanılan yöntemlerden birisidir (Blum, Xue, & Zhang, 2019). Bu yöntemde kaynak görüntüler bir kaynak görüntü ile bulanıklaştırılıp orijinal hali ile farkı alınarak kenar bilgileri vurgulanır. Daha sonra boyutu yarıya indirilerek yukarıya ölçeklenir ve piramidin bir katmanı elde edilmiş olur. Bu işlemler arzu edilen katman miktarı elde edilinceye kadar tekrarlanır. LP yönteminde kaynak görüntülerin piramit verileri arasında MS kuralı kullanılarak birleşik görüntü piramidi üretilmiş olur. Birleşik görüntü için ters piramit işlemler uygulanması yeterlidir. Ayrık dalgacık dönüşümünde (DWT) de benzer bir mantık uygulanmaktadır (Bhavana & Krishnappa, 2015). DWT için filtre olarak ayrık dalgacıklar satır ve sütunlara uygulanır. Her katmanda dört DWT bölgesi oluşmaktadır. Birleştirme işlemi de tıpkı LP yöntemindeki gibi karşılıklı katsayılar arasında MS kuralı uygulanarak seçim yapılmaktadır. Elde edilen birleşik piramide ters DWT işlemi uygulanarak birleşik görüntü elde edilmektedir.

Convolutional Neural Network tabanlı (CNNT) yöntemi kaynak görüntülerden piksel aktivite bilgilerini içeren bir harita çıkartmak için CNN tabanlı bir yapı kullanır (Liu et al., 2018). Derin öğrenme burada iki amaç için kullanılmıştır. Bunlar; kaynaklardaki piksel aktivitelerinin tespiti ve birleştirme katsayısının tespitidir. Görüntüler CNN ağına giriş olarak verilir ve ağ birleştirme katsayılarını içeren haritayı üretir. Kaynak görüntüler Laplas pramidine dönüştürülür ve bu uzayda CNN ağının ürettiği katsayılar ile birleştirilirler. Son olarak ters Laplas dönüşümü ile birleşik görüntü elde edilir.

Deep Learning Framework (DLF) yöntemi derin öğrenme tabanlı bir diğer yöntemdir (Li et al., 2018). Bu yöntemle kaynak görüntüler temel ve detay parçalarına bölünmektedir. Temel parçalar O kuralı kullanılarak birleştirilmektedir. Detay bölgeler için ise derin öğrenme yaklaşımı olarak VGG-19 ağı kullanılarak hesaplanan görüntü özellikleri birleştirme kuralında kullanılmaktadır.

Derin artık ağ (deep residual network-ResNet) tabanlı yöntemde ayrıca sıfır fazlı bileşen analizi (ZCA) kullanılmaktadır (Li et al., 2019). Bu yöntemde kaynak görüntülerin ResNet derin ağ ile özellikleri çıkartılmaktadır. Bu özellikler normalleştirmek için ZCA dönüşümü kullanılmakta ve AO için gerekli katsayıları içeren ağırlık haritası üretilmektedir.

Çekişmeli üretici ağ kullanılarak geliştirilen DDCGAN metodunda üretici ağ gerçeğe yakın birleşik görüntü üretmeyi üstlenirken ayırt edici ağ ise birleşik görüntü ile kaynak görüntüler arasındaki yapısal farklılıkları belirlemektedir (Ma, Xu, Jiang, Mei, & Zhang, 2020). Bu yolla birleşik görüntüde termal

## TAM METİN SÖZEL SUNUMLAR

bilgi ile görünür bölgedeki dokuların aynı anda tutulması zorlanmış olur. Bu yöntemde birleşik görüntü üretici ağ tarafından çıktı olarak verildiği için kaynak verileri arasında bir birleştirme kuralı uygulanması söz konusu değildir. Ağ kendisi birleştirme kuralını kaynak görüntülere göre belirlemektedir.

**Tablo 1. Kullanılan birleştirme yöntemleri ve temel özellikleri**

| Yöntem   | Kategori        | Ağ tipi | Dönüşüm tipi            | Birleştirme kuralı |
|----------|-----------------|---------|-------------------------|--------------------|
| Ortalama | Uzaysal         | -       | -                       | O                  |
| LP       | Dönüşüm tabanlı | -       | Laplas pramidi          | MS                 |
| DWT      | Dönüşüm tabanlı | -       | Ayrık dalgacık Dönüşümü | MS                 |
| CNNT     | Derin öğrenme   | CNN     | Laplasyan pramidi       | AO                 |
| DLF      | Derin öğrenme   | VGG     | l1 norm                 | AO+MS              |
| ResNet   | Derin öğrenme   | ResNet  | ZCA                     | AO                 |
| DDcGAN   | Derin öğrenme   | GAN     | -                       | -                  |

### KALİTE METRİKLERİ

Yapısal Benzerlik (YB): bu metrik kaynak görüntüler arasındaki benzerliği sayısallaştırmaktadır (Wang, Bovik, Sheikh, & Simoncelli, 2004). Ortalama benzerlik indeksi aşağıdaki gibi hesaplanabilir.

$$OYB(x, y) = \frac{1}{M} \sum_{j=1}^M YBI(x_j, y_j) \quad (2)$$

Burada x birleşik görüntü ve y bir kaynak görüntüdür. Sonuç metrik değeri için ayrıca aşağıdaki hesaplamaya da ihtiyaç duyulmaktadır.

$$YBI(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3)$$

Burada  $\mu_x$  ve  $\mu_y$  ortalama değerleri,  $\sigma_x$  ve  $\sigma_y$  ise varyans değerleridir.  $\sigma_{xy}$  değeri görüntülerin kovaryansıdır.  $C_1 = 6.5025$  ve  $C_2 = 58.5225$ . Bu hesaplamalar kullanılarak YB değeri için formül şu şekildedir:

$$YB = OYB(G_x, G_b) + OYB(G_y, G_b) \quad (4)$$

*Birleştirme Faktörü (BF)*: bu metrik kaynak görüntülerden birleşik görüntüye aktarılan bilginin miktarını ölçmek için Kullback-Leibler ölçütünü kullanır (Qu, Zhang, & Yan, 2002). Bu ölçüt şu şekilde hesaplanır:

$$F_{x,y} = \sum_{a,b} P_{x,y}(a, b) \log \frac{P_{x,y}(a, b)}{P_y(a)P_x(b)} \quad (5)$$

Burada  $P_y(a)$  ve  $P_x(b)$  kaynak görüntüler için olasılık yoğunluk fonksiyonu iken  $P_{x,y}(a, b)$  ortak olasılık yoğunluk fonksiyonudur. x ve y kaynak görüntüleri için a ve b değerleri [0, 255] aralığında değerler alan karşılıklı yoğunluk değerleridir. Bu değerlere bağlı olarak birleştirme faktörü değeri f birleşik görüntüsü için şu şekilde hesaplanır:

$$BF = F_{x,f} + F_{y,f} \quad (6)$$

## TAM METİN SÖZEL SUNUMLAR

Kenar Tabanlı Kalite Metriği (KTK): bu metrik kaynak görüntülerden birleşik görüntüye aktarılan kenar bilgisinin miktarını kalite değeri olarak üretmektedir (Xydeas & Petrovic, 2000). x ve y görüntüleri ve b birleşik görüntüsü için KTK metriği aşağıdaki gibi hesaplanır.

$$KTK = \frac{\sum_{i=1}^m \sum_{j=1}^n Q^{xb}(i,j)w^x(i,j) + Q^{yb}(i,j)w^y(i,j)}{\sum_{i=1}^m \sum_{j=1}^n w^x(i,j) + w^y(i,j)} \quad (7)$$

Burada  $Q^{xb}$  ve  $Q^{yb}$  değerleri kaynak görüntülere ait kenar bilgisi koruma değerlerini ifade eder ve ağırlıklandırılmalarında kullanılan değerler sırasıyla  $w_x = [ga(i, j)]L$  ve  $w_y = [gb(i, j)]L$  şeklinde hesaplanır. Kenar bilgisi sobel operatörü kullanılarak hesaplanır ve denklemden büyüklükleri ga ve gb ile ifade edilmektedir. L ise önceden belirlenen sabittir.

Standart Sapma (SS): bir görüntüdeki yoğunluk değerlerinin çeşitliliği kalitenin bir göstergesidir. Bu maksatla yoğunluk değerlerinin standart sapması sıklıkla kullanılmaktadır:

$$SS = \sqrt{\frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [x(i, j) - \bar{x}]^2} \quad (8)$$

Burada  $\bar{x}$  değeri x görüntünün yoğunluk değerlerinin ortalamasıdır.

Uzaysal Frekans (UF): satır ve sütunlardaki yoğunluk değerlerinin farkları toplamın gradiyenti olarak tanımlanır (Eskicioglu & Fisher, 1995).

$$C = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [G(i, j) - G(i - 1, j)]^{1/2} \quad (9)$$

$$R = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [G(i, j) - G(i, j - 1)]^{1/2} \quad (10)$$

Burada sırasıyla birleşik görüntüye ait satır ve sütunlardaki yoğunluk değerleri değişimlerinin toplamını C ve R ile ifade edilmiştir. UF değeri ise şu şekilde hesaplanır:

$$UF = \sqrt{R^2 + C^2} \quad (11)$$

Farklar Korelasyonu (FK): kaynak görüntü ile birleşik görüntü arasındaki farkın diğer kaynak görüntünün katkısı olduğu fikrine dayanır (Aslantas & Bendes, 2015). Kaynak görüntülerin katkılarını hesaplamak için öncelikle birleşik görüntü ile piksel tabanlı fark hesaplanır.

$$f_x = G_b - G_x \text{ ve } f_y = G_b - G_y \quad (12)$$

Bu farkların diğer kaynak görüntü ile Pearson korelasyonlarının toplamı aşağıdaki gibi FK değerini verecektir:

$$FK = r(G_b, f_x) + r(G_b, f_y) \quad (13)$$

Burada r parametredeki görüntüler arasındaki pearson korelasyonunu ifade etmektedir.

# TAM METİN SÖZEL SUNUMLAR

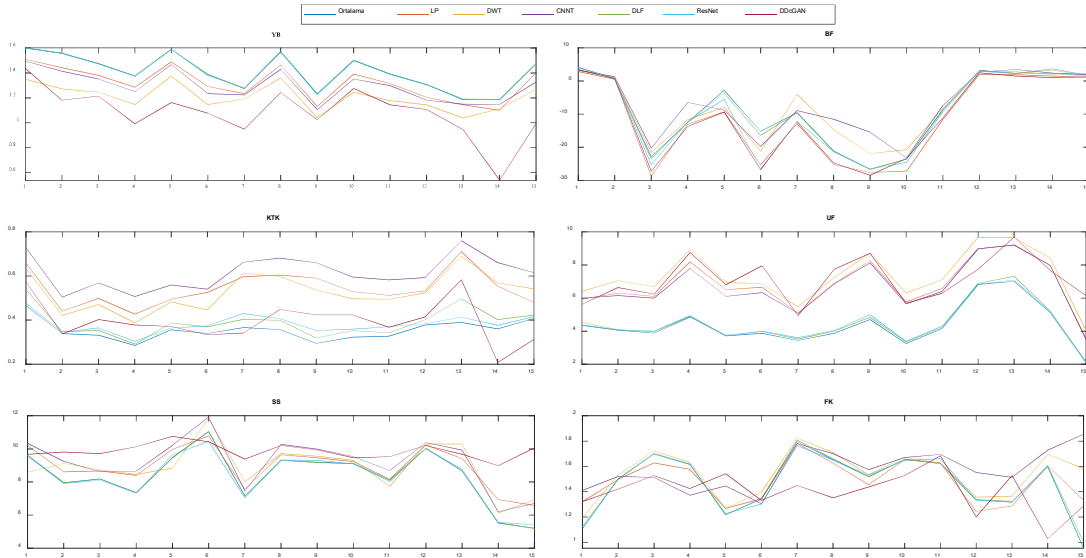
## DENEYSEL SONUÇLAR

Deneysel çalışmalarda 15 termal ve görünür bölge görüntü çifti kaynak görüntü olarak kullanılmıştır. Görüntüler içinde literatürde sıklıkla kullanılan TNO görüntüleri bulunmaktadır. Ayrıca, ek olarak yayınlarında kullanılmamış görüntüler eklenerek deneysel veriler oluşturulmuştur. Deneylerde kullanılan derin öğrenme temelli metotlarda kullanılan YSA lar ilgili çalışmalarda eğitildiği halleri ile kullanılmıştır. Herhangi bir eğitim süreci bu çalışmada yürütülmemiş sadece yöntemlerin eğitilmiş hallerinin kıyaslanması amaçlanmıştır.

Şekil 1’de yöntemlerin testlerde kullanılan 6 farklı metrik için kantitatif analizi verilmiştir. Bütün metriklerde büyük değer daha iyi kaliteyi temsil etmektedir. Her metrik için ayrı ayrı verilen grafiklerde yatay eksen test görüntülerini dikey eksen ise metrik değerini ifade etmektedir. Özellikle kaynak görüntüleri değerlendirilmede kullanılan YB, BF, KTK ve FK gibi metriklerde derin öğrenme temelli yöntemlerin iyi sonuçlar verdiği gözlemlenmektedir. YB metriği için en iyi sonucu ResNet ağı verirken DLF ve ortalama yöntemlerin de yakın değerler ürettiği not edilmiştir. BF metriği için ResNet ve DDcGAN ağlarının üstün sonuçlar verdiği görülmektedir. FK ve KTK metrikleri açısından CNNT yöntemi öne çıkarken, UF metriği LP ve DWT gibi klasik yöntemleri vurgulamıştır.

Şekil 2’de görsel sonuçlar paylaşılmıştır. Görsel sonuçlar incelendiği zaman DDcGAN ve CNNT yöntemleri termal detayları birleşik görüntüye aktarmakta başarılı oldukları görülmektedir. DWT sonuçları yapay dokular içerirken, genel olarak derin öğrenmeli metotların detayları vurgulamakta daha başarılı oldukları gözlemlenmiştir. DDcGAN metodu termal bilgileri vurgularken görünür bölge detaylarını da koruduğu görülmektedir.

**Şekil 1. Yöntemlerin test görüntüleri için kalite metrikleri bazında sayısal kıyaslaması**




## SONUÇ

Bu çalışmada literatürde önerilmiş görüntü birleştirmede derin öğrenme kullanan yaklaşımlar klasik yöntemler ile kıyaslanmıştır. Kıyaslamada 15 termal ve görünür bölge görüntüsü çifti kullanılmıştır. Elde edilen sonuç farklı objektif görüntü birleştirme kalite metrikleri kullanılarak değerlendirilmiştir.

## TAM METİN SÖZEL SUNUMLAR

Elde edilen sonuçlar değerlendirildiğinde derin öğrenme ile literatürde önerilmiş yöntemlerin klasik görüntü birleştirme yöntemlerine göre daha iyi sayısal ve görsel sonuçlar ürettiği görülmüştür. Derin ağların eğitiminde kullanılmamış kaynak görüntülerde dahi daha iyi sonuçlar üretebiliyor olması YSA modellerinin genelleştirme özelliğinin görüntü birleştirme sonuçlarına da olumlu yansıdığına bir göstergesidir.

Şekil 2. Görsel sonuçlar



### KAYNAKÇA

Aslantas, V., & Bendes, E. (2015). A new image quality metric for image fusion: The sum of the correlations of differences. *AEU - International Journal of Electronics and Communications*, 69(12). Retrieved from <https://doi.org/10.1016/j.aeue.2015.09.004>

Aslantas, V., Bendes, E., Kurban, R., & Toprak, A. N. (2014). New optimised region-based multi-scale image fusion method for thermal and visible images. *IET Image Processing*, 8(5). Retrieved from <https://doi.org/10.1049/iet-ipr.2012.0667>

- Bhavana, V., & Krishnappa, H. K. (2015). Multi-Modality Medical Image Fusion using Discrete Wavelet Transform. *Procedia Computer Science*, 70, 625–631. Retrieved 18 December 2022 from <https://doi.org/10.1016/J.PROCS.2015.10.057>
- Blum, R. S., Xue, Z., & Zhang, Z. (2019). An Overview of Image Fusion \*. *Multi-Sensor Image Fusion and Its Applications*, 1–36. Retrieved 18 December 2022 from <https://doi.org/10.1201/9781315221069-1/Overview-Image-Fusion-Rick-Blum-Zhiyun-Xue-Zhong-Zhang>
- Eskicioglu, A. M., & Fisher, P. S. (1995). Image Quality Measures and Their Performance. *IEEE Transactions on Communications*, 43(12), 2959–2965. Retrieved 20 December 2022 from <https://doi.org/10.1109/26.477498>
- Li, H., Wu, X. J., & Kittler, J. (2018). Infrared and Visible Image Fusion using a Deep Learning Framework. *Proceedings - International Conference on Pattern Recognition*, 2018-August, 2705–2710. Retrieved 7 December 2022 from <https://doi.org/10.1109/ICPR.2018.8546006>
- Li, H., Wu, X. jun, & Durrani, T. S. (2019). Infrared and visible image fusion with ResNet and zero-phase component analysis. *Infrared Physics & Technology*, 102, 103039. Retrieved 7 December 2022 from <https://doi.org/10.1016/J.INFRARED.2019.103039>
- Liu, Y., Chen, X., Cheng, J., Peng, H., & Wang, Z. (2018). Infrared and visible image fusion with convolutional neural networks. *International Journal of Wavelets, Multiresolution and Information Processing*, 16(3). Retrieved 10 December 2022 from <https://doi.org/10.1142/S0219691318500182>
- Ma, J., Xu, H., Jiang, J., Mei, X., & Zhang, X. P. (2020). DDcGAN: A Dual-Discriminator Conditional Generative Adversarial Network for Multi-Resolution Image Fusion. *IEEE Transactions on Image Processing*, 29, 4980–4995. Retrieved 19 December 2022 from <https://doi.org/10.1109/TIP.2020.2977573>
- Qu, G., Zhang, D., & Yan, P. (2002). Information measure for performance of image fusion. *Electronics Letters*, 38(7), 313–315. Retrieved 20 December 2022 from <https://doi.org/10.1049/EL:20020212>
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. Retrieved 20 December 2022 from <https://doi.org/10.1109/TIP.2003.819861>
- Xydeas, C. S., & Petrovic, V. S. (2000). Objective pixel-level image fusion performance measure. *https://Doi.Org/10.1117/12.381668*, 4051, 89–98. Retrieved 20 December 2022 from <https://doi.org/10.1117/12.381668>