



## Landsat Uydu Görüntülerinde Derin Öğrenme Tabanlı Tek Görüntülü Süper-Çözünürlük Deneyleri

Serdar ÇİFTÇİ<sup>1,\*</sup>, Muhittin KARAMAN<sup>2</sup>

<sup>1</sup>Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 63100, Haliliye/ŞANLIURFA

<sup>2</sup>İstanbul Teknik Üniversitesi, Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, 34469, Maslak/İSTANBUL

### Öz

Erişime açık olarak sunulan uydu görüntülerinin uzamsal çözünürlükleri genellikle düşük olup, bu görüntüler detay çıkarımı ve hassas çalışmalar yapmak için yetersizdir. Uydu görüntülerindeki düşük uzamsal çözünürlük, uzaktan algılama çalışmalarında konunun türüne bağlı olarak başarımları düşürmektedir. Bu olumsuz durumun üstesinden gelmek için süper-çözünürlük ve pan-keskinleştirme algoritmaları kullanılarak düşük çözünürlüklü görüntüler yüksek çözünürlüklü hale getirilir. Bu çalışmada, süper-çözünürlük deneyleri için derin öğrenme tabanlı hazır eğitilmiş EDSR ve DBPN modelleri ve görüntü işleme tabanlı Bikübic yöntemi kullanılmış ve sonuçlarının pan-keskinleştirme ile benzerliği değerlendirilmiştir. Yapılan deneyler sonucunda EDSR ve DBPN modellerinin Bikübic yöntemine kıyasla daha keskin geçişli görüntüler ürettiği, ancak üretilen görüntülerde çizgisellikleri bozduğu ve objektif değerlendirmelerde daha zayıf kaldıkları gözlenmiştir.

### Makale Bilgisi

Başvuru: 31/10/2020

Yayın: 25/12/2020

### Anahtar Kelimeler

Süper-çözünürlük

Derin Öğrenme

EDSR

DBPN

Bikübic

Landsat-8

Pan-keskinleştirme

### Deep Learning Based Single Image Super-Resolution Experiments on Landsat Satellite Images

### Abstract

The spatial resolutions of publicly available satellite images are generally low, and these images are insufficient for detail extraction and careful studies. Depending on the type of subject, satellite images in low spatial resolution can reduce remote sensing studies' performance rate. Low-resolution images are transformed into high resolution by using super-resolution and pan-sharpening algorithms to overcome this unfavorable situation. In this study, for super-resolution experiments, deep-learning based pretrained EDSR and DBPN models and image-processing based Bicubic method were used, and the similarity of their results to pan-sharpening was evaluated. Experiments show that the EDSR and DBPN models produced sharper transition images compared to the Bicubic method, but they distorted the line based structures in the produced images and remained weaker in objective evaluations.

### Keywords

Super-resolution

Deep Learning

EDSR

DBPN

Bicubic

Landsat-8

Pansharpening

## 1. GİRİŞ (INTRODUCTION)

Süper-çözünürlük kavramı, düşük çözünürlüklü görüntüden yüksek çözünürlüklü görüntü elde etmeyi ifade eder. Bu işlem, tek bir düşük çözünürlüklü görüntü kullanılarak yapılabileceği gibi aynı görüntünün farklı şekillerde temin edilmiş hallerinin kullanılmasıyla da yapılabilir. Elde edilmiş yüksek çözünürlüklü görüntünün keskin geçişler içermesi, görüntünün netliğini belirleyen önemli faktörlerden biridir. Klasik görüntü işleme tabanlı yaklaşımlarla piksellerin komşuluk ilişkilerine göre *en yakın*, *bilineer*, *bikübic* gibi yöntemler kullanılarak düşük çözünürlüklü görüntüler yüksek çözünürlüklü hale getirilebilmektedir [1]. Yalnız, bu yöntemlerle elde edilmiş yüksek çözünürlüklü görüntüler keskin olamamakta ve görüntü kalitesi düşük olabilmektedir [2].

\* Serdar ÇİFTÇİ, e-mail: serdarciftci@harran.edu.tr

Derin öğrenme alanındaki gelişmeler süper-çözünürlük çalışmalarını da etkilemiş ve oldukça başarılı sonuçların alındığı gözlenmiştir [3][4]. Bu önemli gelişmeyle süper-çözünürlük; görüntülerde nesne bulma, yüz tanıma, tıbbi görüntüleme, uzaktan algılama, astronomi, sıkıştırılmış görüntü/video iyileştirme, işaret/plaka tanıma ve suç analizi gibi çeşitli alanlarda kendisine uygulama alanı bulmuştur [4].

Uzaktan algılama alanında uydulardaki algılayıcılar misyonuna göre belirli bir zamansal çözünürlükte yer yüzeyinde görüntüleme yaparlar. Zamansal çözünürlüklerine bağlı olarak da belirli bir süre içerisinde yer yüzeyinin tamamını görüntülerler. Yine uyduların misyonlarına göre konumlandırıldıkları yörüngeleri, algılayıcının teknik özellikleri ve uydunun yörüngelerine bağlı olarak yer yüzeyindeki kapsama alanları ve elde edilen görüntülerin uzamsal çözünürlükleri farklılık gösterir. Uydu görüntüleri, sağlayıcıları tarafından ücretli veya ücretsiz olarak son kullanıcıların kullanımına sunulmaktadır. Düşük uzamsal çözünürlüklü USGS (Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu) [5] tarafından sağlanan Landsat-8 OLI/TIRS (30m multispektral, 15m pankromatik) ve ESA (Avrupa Uzay ajansı) [6] tarafından sağlanan Sentinel-2 (10m, 20m, 60m) uydu görüntüleri, ücretsiz kullanıma açık olan uydu görüntülerine örnektir. Yüksek uzamsal çözünürlüklü uydu görüntüleri (WorldView-4, Geoeye, Pleiades) genelde ücretli olarak sağlanan görüntülerdir. Düşük uzamsal çözünürlüklü uydu görüntülerinin farklı uygulama konularında, çözünürlüklerinin getirmiş olduğu dezavantajları kullanımlarını kısıtlar.

Bu çalışmada derin öğrenme yöntemleri ile düşük uzamsal çözünürlüklü uydu görüntülerinin uzamsal çözünürlüklerinin artırılması test edilerek, diğer düşük uzamsal çözünürlüklü uydu görüntülerinin benzer şekilde uzamsal çözünürlüklerin artırılması ve kullanım alanlarının genişletilmesi amacıyla deneyler yapılmıştır. Bu bağlamda ücretsiz olarak sunulan düşük uzamsal çözünürlüklü Landsat-8 OLI/TIRS uydu görüntülerinin uzamsal çözünürlüklerinin artırılmasında hazır eğitilmiş derin öğrenme modellerinin başarımı incelenmiştir. Derin öğrenme tabanlı EDSR [7], DBPN [8] ve görüntü işleme tabanlı biküçük interpolasyon yöntemleriyle iki kat süper-çözünürlük elde edilip bu görüntülerin Pan-keskinleştirme yöntemiyle elde edilmiş görüntülere ne kadar yaklaştığı incelenmiştir.

## 2. LİTERATÜR TARAMASI (RELATED WORK)

Süper-çözünürlük çalışmaları derin öğrenmenin yaygınlaşmasından önce başlamış olup yaklaşımlarına göre frekans alanında veya uzamsal alanda, çok görüntü veya tek görüntü kullanarak, öğrenme veya yapılandırma tabanlı olmak üzere sınıflandırılabilir [9]. Bu çalışmada tek görüntülü süper-çözünürlük deneyleri yapıldığından tek görüntü kullanarak görüntü işleme ve derin öğrenme tabanlı bazı çalışmalara değinilecektir.

### 2.1 Görüntü İşleme Tabanlı Yaklaşımlar

Uydu görüntülerinde yüksek frekanslı pikseller kaybolabildiğinden bu görüntüler flu olarak görünebilmektedir [10]. Bu etkiyi azaltmak ve görüntü netliğini artırmak için yüksek frekanslı piksellerin belirginliği artırılır. Bunun için izlenen yol, görüntüyü dört farklı dalga boyuna (düşük-düşük, düşük-yüksek, yüksek-düşük ve yüksek-yüksek) ayırmaktır. Tahmin edilen yüksek frekans dalga boyutlu görüntü ile daha önceden elde edilmiş olan düşük dalga boyutlu görüntünün dalgacık katsayıları interpolasyonu yapılarak süper-çözünürlüklü görüntü elde edilir [11]. Bu dalgacık yaklaşımı, görüntüdeki yüksek frekansları korumak ve daha keskin görüntüler elde etmek amacıyla kullanılır [11].

Görüntü işleme tabanlı yaklaşımlar, genel olarak piksellerin komşuluk değerlerini kullanarak ara değerleri interpolasyon yöntemiyle belirler [12]. Bilineer, biküçük yöntemler aralık değerleri için sırasıyla birer doğru veya yüzey oturtmaya çalışırlar. Bu şekilde komşuluk ilişkisi kullanılarak çözünürlüğü artırılan görüntüler genelde flu olmaktadır [2].

Bu yaklaşımlar haricinde görüntü türevleri, görüntüde yer alan ilkel skeçler, özellik piramitleri ve yansımaların kullanıldığı yöntemler de sıkça kullanılmaktadır [9].

## 2.2 Derin Öğrenme Tabanlı Yaklaşımlar

Derin öğrenme alanındaki gelişmeler, süper-çözünürlük çalışmalarını etkilemiş ve başarılı sonuçlar alındığı gözlenmiştir [3][4]. Derin öğrenme tabanlı yöntemler kendi içlerinde ağ mimarisi türüne, kullanılan hata fonksiyonu türüne ve farklı öğrenme prensiplerine göre gruplanabilir. Sıkça kullanılan modeller: evrişimsel, artık blok kullanımı, rekürsif, yoğun bağlantılı, dikkat tabanlı ve çekişmeli üretken ağlardır [4].

Deneylerimizde sırasıyla evrişimsel ve artık blok ağ mimarisi kullanarak süper-çözünürlük elde eden EDSR [7] ve DBPN [8] yöntemleri kullanılmış ve bu yöntemlere 3.1 ve 3.2 kısımlarında değinilmiştir.

## 3. YÖNTEM (METHODOLOGY)

Bu çalışmada aşağıda belirtilen yöntemlerle 30 metre çözünürlüklü Landsat-8 OLI/TIRS renkli görüntüler girdi olarak alınıp iki kat büyütülerek 15 metre süper-çözünürlüklü yeni görüntüler elde edilmiştir. Yeni süper-çözünürlüklü görüntüler Gram-Schmidt yöntemi ile pan-keskinleştirilmiş 15 metre çözünürlüklü renkli Landsat-8 OLI/TIRS görüntüsü ile karşılaştırılmıştır.

### 3.1 Enhanced Deep Residual Networks for Single Image Super-resolution (EDSR)

Lim vd. [6] evrişimsel sinir ağlarında artık bloklar, ağ üzerinde katmanlar arasında bilgi aktarımının sıralı olmasının yanında sıra gözetmeden daha ileri katmanlara da aktarılmasını, kullanarak süper çözünürlük elde etmeyi amaçlamışlardır. Artık bloklarda yığın normalizasyonu kullanmadıklarından hesaplama karmaşıklığı az olduğu gibi daha keskin görüntüler elde etmişlerdir. Görüntünün uzamsal çözünürlüğünü iki katına çıkarmak için model baştan eğitilirken diğer katlar için başlangıç değeri olarak iki katını eğitirken elde edilmiş olan değerler kullanılır. EDSR modelini kullanarak süper-çözünürlüklü görüntüler elde etmek için [13] adresindeki kodlar kullanılmıştır.

### 3.2 Deep Back-projection Networks for Super-resolution (DBPN)

DenseNets [14] mimarisindeki katmanlar arasındaki yoğun bağlantı düzeni türevlerin yok olmasını azalttığından, özellikler korunabilmekte ve tekrardan kullanılabilir. DBPN [7] mimarisi, DenseNets mimarisinden esinlenmiş olup yansıtma birimlerinde, bir önceki katmandan gelen görüntüyü büyütüp veya küçülttükten sonra eski haline döndürüp aradaki hatayı hesaplama modülü, yoğun bağlantılar kullanmayı önermiştir. Diğer mimarilerde ileri beslemeli ağlar kullanarak süper çözünürlük tahmin edilirken DBPN mimarisinde çoklu yükseltme ve düşürme örnekleri kullanılarak her derinlikte hata beslemesi yapılır ve örnekler ağ tarafından gözden geçirilir. Yükseltme aşamasında doğrulanan özellikler toplanır. Normal DenseNets mimarisinde kullanılan nod iptali (dropout) ve yığın normalizasyonu kullanılmamıştır. Bunun nedeni özelliklerin esnekliğinin kaybolması ve bu durumun süper çözünürlük için uygun olmamasıdır. Ağ üzerinde yansıtma birimine girmeden önce özellik havuzlama ve boyut düşürme için 1x1 evrişimsel katman kullanılmıştır. DBPN modelini uygulamak için [15] adresindeki kodlardan yararlanılmıştır.

### 3.3 Biküçük İnterpolasyonu

İnterpolasyon fonksiyonu, özel bir yaklaşım türü fonksiyonudur. Sayısal görüntü işlemede görüntüyü büyütme ya da küçültme için sıkça kullanılmaktadır. İnterpolasyon fonksiyonlarının önemli özelliği örneklenen veri ile interpolasyon noktalarında kesişme göstermeleridir. Biküçük interpolasyon dört nokta arasına üçüncü dereceden bir denklem kullanarak yüzey oturtmaya çalışır [1]. Bu yüzey denklemi için 16 katsayıya ihtiyaç duyar ve bu değerlerin dördü köşelerin yoğunluk değerinden, sekizi yatay ve dikey türevlerinden, son dördü de köşegen türevlerinden elde edilir. Bilineer ve en yakın komşuluklu interpolasyona göre matematiksel olarak daha karmaşık olmasına rağmen daha az bozulmayla interpolasyon işlemini gerçekleştirir. Bu çalışmadaki biküçük interpolasyon sonuçları [16] adresindeki kodlar kullanılarak elde edilmiştir.

## 4. DENEYLER (EXPERIMENTS)

### 4.1 Veri Kümesi

#### 4.1.1 Landsat Uydu Görüntüsü

Farklı yöntemlerle Gram-Schmidt pan-keskinleştirme yönteminin karşılaştırıldığı bu çalışmada USGS (Amerika Birleşik Devletler Jeoloji Araştırmaları) [5] tarafından ücretsiz olarak dağıtımı yapılan 11.08.2020 tarihli ve 179/34 path/row çerçeve lokasyonlu Landsat-8 OLI/TIRS uydu görüntüsü kullanılmıştır. Çerçevedeki bulutluluk oranı %1.28 ve OLI algılayıcısı görüntü kalitesi 9'dur. Kullanılan görüntü geometrik olarak UTM (Universal Transverse Mercator) projeksiyonu, WGS-84 datumu ve 35. zona göre referanslıdır. Görüntünün işleme seviyeleri, radyometrik kalibrasyon ve ortorektifikasyon işlemlerini içeren L1TP'dir.

185x180 km çerçeve boyutunda görüntü sağlayan Landsat-8 OLI/TIRS uydusu, görünür ve kızılötesi dalga boyu aralığında algılama yapan OLI algılayıcısı ile birlikte termal kızıl ötesi dalga boyu aralığında algılama yapan TIRS algılayıcısını içerir [17][18]. OLI algılayıcısı ile 30m uzamsal çözünürlüklü 8 kanal elektromanyetik spektrumun görünür bölgesi ve kızılötesi bölgesi ile 15m uzamsal çözünürlüklü pankromatik görüntü elde edilirken, TIRS algılayıcısı ile 100m uzamsal çözünürlüklü 2 kanal termal kızıl ötesi görüntüsü elde edilir [17][18].

#### 4.1.2 Test Alanları

185x180 km çerçeve boyutlu Landsat-8 OLI/TIRS görüntüsünde, 10 farklı test alanı belirlenmiştir. Uydu görüntüsü çerçevesi içinde kalan göl (sığ, derin, tatlı, tuzlu), deniz, baraj, tarım arazisi, şehir gibi farklı arazi örtüsü sınıflarını temsil eden test alanları seçilmiştir. Seçilen test alanları bölgesel isimlerine göre sırasıyla Acıgöl (Denizli), Acıpayam Ovası (Denizli), Burdur Gölü, Denizli, Denizli Organize Sanayi Bölgesi, Fethiye, Gökova Körfezi, Köyceğiz Gölü, Manisa-Sarıgöl ve Salda Gölü'dür.

#### 4.1.3 Referans Görüntüsünün Hazırlanması

Her bir test alanının çerçeve boyutu 600x600 pikseldir. Test alanı için kullanılacak alt çerçeve görüntüleri, aynı tarihli tek bir Landsat çerçevesinin farklı bölgelerinden kesilmek suretiyle üretilmiş olup Şekil-1'de gösterilmiştir. Kullanılan görüntülerde sırasıyla atmosferik düzeltme, pan-keskinleştirme, RGB doğal renkli görüntü çıkarımı işlemleri yapılmıştır. Girdi verisi olarak kullanılmak üzere, test alanlarına ait sadece atmosferik düzeltmesi yapılmış 30m uzamsal çözünürlüklü 600x600 piksel boyutlu görüntüler üretilmiştir. Derin öğrenme ve bikübbik yöntemlerinin sonuçlarının karşılaştırılacağı referans görüntünün atmosferik düzeltmesi yapılmıştır. 30m uzamsal çözünürlüklü Landsat-8 OLI/TIRS uydu görüntüsünün pan-keskinleştirme ile elde edilen 15m uzamsal çözünürlüklü, 1200x1200 piksel boyutlu, görüntüler oluşturulmuştur.

##### i) *Atmosferik Düzeltme*

Atmosferin uydu görüntüsü üzerindeki etkilerini ortadan kaldırmak ve arazi örtüsü bileşenlerinin yer yüzeyindeki yansımalarını elde etmek amacıyla QUAC algoritması [19] kullanılarak atmosferik düzeltme yapılmıştır. QUAC yöntemi, uydu görüntüsündeki bantların dalga boyu bilgileri ve radyometrik kalibrasyon bilgileri dışında yersel ve atmosfer hakkında herhangi bir veriye ihtiyaç duymamasından dolayı tercih edilmiştir.


##### ii) *Pan-keskinleştirme*

Multispektral görüntünün uzamsal çözünürlüğünün 30m'den 15m'ye yükseltilmesi, 15m çözünürlüklü pankromatik bant kullanılarak pan-keskinleştirilme işlemi ile gerçekleştirilmiştir. Pan-keskinleştirme için Gram-Schmidt [20] algoritması kullanılmıştır. Gram-Schmidt algoritmasıyla pan-keskinleştirilmiş

görüntüler, orijinal görüntülerdeki nesnelerin uzamsal ve spektral özelliklerini korumada başarılıdır [21]. Görüntü keskinliğini en üst düzeye çıkarma, renk bozulmasını en aza indirme konularındaki başarılı performansından dolayı Gram-Schmidt yöntemi uygulanmıştır [22]. Laben vd. [20] tarafından geliştirilen Gram-Schmidt yönteminde pan-keskinleştirme işlemi dört aşamada tamamlanır. Bu aşamalar; i) düşük renkli çok bantlı görüntülerden bantların ortalaması [21] alınarak yeni pankromatik bandın üretilmesi, ii) yeni üretilen pankromatik bandın ilk bant olarak kullanılması ile çok bantlı renkli görüntülerde ve yeni üretilen pankromatik bantta Gram-Schmidt dönüşümünün yapılması, iii) yüksek çözünürlüklü pankromatik bant ile birinci Gram-Schmidt bandının yer değiştirmesi, iv) Gram-Schmidt dönüşümünün yapıldığı çok bantlı görüntüye ters Gram-Schmidt dönüşümünün yapılmasıdır [23].

### iii) RGB görüntü üretimi

Referans ve girdi görüntüleri, Landsat-8 OLI/TIRS uydu görüntüsünün Band4 (Kırmızı: 0.64-0.67 $\mu$ m), Band3 (Yeşil: 0.53-0.59 $\mu$ m) ve Band2 (Mavi: 0.45-0.51 $\mu$ m) kanallarından oluşturulan doğal renkli RGB görüntülerinden elde edilmiştir.



**Şekil-1:** 11.08.2020 tarihli Landsat-8 OLI/TIRS görüntüsünden üretilen test alanlarına ait alt çerçeve sınırları.

## 4.2 Kullanılan Metrikler

Süper-çözünürlük uygulanarak elde edilmiş görüntülerin kalitesi, görüntü işlemede yaygın olarak kullanılan 4 farklı metrik ile yapılmıştır. Kullanılan bu metrikler aşağıda detaylandırılmıştır. Metrik hesaplamaları için Python Sewar<sup>1</sup> kütüphanesi kullanılmıştır.

### 4.2.1 Structural Similarity Index Measure (SSIM)

Wang vd. [12] bir görüntünün kendisine verilmiş bir referans görüntüsü ile karşılaştırmasında insan görme sistemindeki algılamaya uygun şekilde üç bileşenin karşılaştırmasını kullanmışlardır. Bu bileşenler; parlaklık değişimi, kontrast değişimi ve görüntünün yapısıdır. Parlaklık değişimi için görüntülerin yoğunluk ortalama değerleri, kontrast değişimi için görüntülerin standart sapmaları ve görüntü yapı değişimi için de görüntülerin ilgili standart sapmaları ile normalize edilmiş halleri karşılaştırılır. SSIM hesaplama sonuçları 0 ile 1 değerleri arasında değişmektedir. En yüksek değerini, 1 değerini, kendisiyle karşılaştırıldığı durumda elde edilebilmektedir.

### 4.2.2 Peak Signal-to-Noise Ratio (PSNR)

PSNR metriği görüntülerdeki en yüksek değer (Peak Signal) görüntüler arasındaki farkların ortalamasına (Mean Square Error, MSE) oranıyla hesaplanır ve logaritmik desibel ölçeğiyle ifade edilir [24]. MSE değerinin sıfıra yaklaşması durumunda PSNR değeri sonsuza yaklaşır. Dolayısıyla PSNR değerinin yüksek çıkması görüntünün yüksek kalitede olduğunu gösterir.

### 4.2.3 Universal Quality Index (UQI)

Wang ve Bovik [25] görüntüdeki bozulmayı modellemek için üç bileşen kullanmışlardır ve bunlar korelasyon kaybı, parlaklık bozukluğu ve kontrast bozukluğudur. Korelasyon kaybı iki görüntü arasındaki lineer korelasyonu gösterir ve -1 ile +1 arasında değer alabilir. Parlaklık bozukluğu 0 ile +1 arasında değer alıp ortalama parlaklığın görüntülere olan uzaklığını ifade eder. Kontrast bozukluğu ise iki görüntünün standart sapmalarının benzerliğini ölçer. UQI metrik hesaplaması yapılırken bu üç bileşen çarpılır ve sonucu -1 ile +1 arasında değer olabilmektedir. En iyi kaliteye +1 değerinde ulaşılır ki bu durum görüntülerin aynı olması durumudur.

### 4.2.4 Visual Information Fidelity (VIF)

Sheikh ve Bovik [26], sinyal iletişimde sinyallerin iletişim kalitesinin ölçümünde kullanılan bilgi teorisine dayanarak bu modeli sunmuşlardır. Bu metrik iki görüntü arasında paylaşılan bilginin ilişkisini ölçer. Referans görüntüdeki bilgilerin ölçülmesi ve bu bilgilerin bozulmuş görüntüde ne kadarı bulunmaktadır ölçümü yapıldıktan VIF metriği hesaplanır. VIF metrik değeri 0 ile 1 aralığındadır ve 1 değeri görüntülerin aynı olması durumunda elde edilir. Özel bir durum olarak görüntü eklenmeden referans görüntüsünün kontrastının lineer bir şekilde iyileştirilmesi durumunda VIF değeri 1'den büyük bir değer verebilir. Bu durum, kontrastı iyileştirilmiş referans görüntüsünün normal referans görüntüsünden daha yüksek kaliteli olduğunu gösterir.

## 4.3 Bulgular

10 farklı test görüntüsü kullanılarak deneyler yapılmıştır. Sonuçların görsel olarak sunulmasında test görüntülerinden belirli bölgeler seçilmiştir. Örneğin Acıgöl'deki havuzların olduğu bölgelerde değişik yöntemlerin sonuçlarının sunulması için sarı çerçevedeki alan belirlenmiştir (Şekil-2). Bu alanın boyutu 600x600 orijinal görüntüde 50x50 pikseldir. Aynı alanın farklı yöntemlerle üretilmiş 1200x1200 boyutlu süper-çözünürlüklü görüntülerdeki boyutu ise 100x100 pikseldir.


<sup>1</sup> <https://pypi.org/project/sewar/>

Orijinal Landsat-8 OLI/TIRS 600x600 piksellik görüntülerden 50x50 piksellik (Şekil-3 a, Şekil-4 a) ve süper-çözünürlük yöntemleriyle çözünürlüğü artırılmış 1200x1200 piksellik görüntülerden de 100x100 piksellik alanlar (Şekil-3 b-e ve Şekil-4 b-e) gösterilmiştir. Sonuç görüntülerinde EDSR ve DBPN yöntemlerinin Bikübik yöntemine kıyasla daha keskin görüntüler üretmesine rağmen farklı arazi örtülerinde çizgiselliği bozdukları görülmüştür. Bu etki özellikle şehir alanlarında, yollarda, göl kenarlarında ve kıyı çizgilerinde kendisini daha güçlü göstermektedir. Aynı şekilde tuz üretiminin gerçekleştiği yapay üretim havuzlarının kenarındaki çizgiselliklerin bozulduğu görülmektedir (Şekil-4 1. satır).



**Şekil-2:** a) 600x600 Landsat-8 OLI/TIRS orijinal görüntü, b) 50x50 piksel boyutlu Landsat-8 OLI/TIRS orijinal görüntü, c) 100x100 piksel boyutlu pan-keskinleştirilmiş görüntü, d-f) 100x100 piksel boyutlu EDSR, DBPN ve Bikübik yöntemleriyle elde edilmiş süper-çözünürlüklü görüntü.

Objektif değerlendirmeler için 600x600 piksel boyutlu orijinal Landsat-8 OLI/TIRS görüntüsünden EDSR, DBPN ve Bikübik yöntemleriyle 2 kat süper-çözünürlükle elde edilmiş 1200x1200 piksel boyutlu görüntülerin, pan-keskinleştirme ile elde edilmiş görüntülere olan benzerliklerine ait metrik sonuçları Tablo-1'de gösterilmiştir. SSIM, PSNR, UQI ve VIF metrikleri kullanılmış olup Bikübik yöntemi daha başarılı bir performans sergilemiştir (Tablo-1). Bu sonucun hazır eğitilmiş EDSR ve DBPN'nin varsayılan modellerinin kullanılmasından kaynaklandığı düşünülmektedir. Şayet bu modellerin uydu görüntüleri ile eğitilmesi durumunda sonuçların daha iyi olacağı beklenilmektedir. EDSR ve DBPN yöntemlerinin sonuçlarına ait SSIM, UQI ve VIF metrik değerleri aynıdır. EDSR, DBPN'e nazaran PSNR metriğinde daha iyi sonuç verse de sonuçlar birbirine oldukça yakındır. Yöntemlerin metrik sonuçlarındaki bu yakınlık durumunun, farklı görüntü kümeleri kullanılmış olmasına rağmen Haris vd. [8]'nin deneylerinde elde etmiş oldukları EDSR ve DBPN sonuçlarının yakınlık durumuna oldukça benzer olduğu görülmüştür.




**Şekil-3:** a) Orijinal 50x50 piksellik görüntü, b) 100x100 piksellik pan-keskinleştirilmiş referans görüntü, c-e) 100x100 piksellik süper-çözünürlük sonuç görüntüleri.

**Tablo-1:** EDSR, DBPN ve Bikübik yöntemleriyle süper-çözünürlüklenendirilmiş görüntülerin Gram-Schmidt yöntemi ile pan-keskinleştirilmiş referans görüntülerine göre benzerlik metrik sonuçları.

	<b>SSIM</b>	<b>PSNR</b>	<b>UQI</b>	<b>VIF</b>
<b>EDSR</b>	0.72	20.49	0.92	0.25
<b>DBPN</b>	0.72	20.39	0.92	0.25
<b>Bikübik</b>	0.75	21.53	0.92	0.32





**Şekil-4:** a) Orijinal 50x50 piksellik görüntü, b) 100x100 piksellik pan-keskinleştirilmiş referans görüntü, c-e) 100x100 piksellik süper-çözünürlük sonuç görüntüleri.

## 5. SONUÇ (CONCLUSION)

Süper-çözünürlük çalışmaları uzunca bir süredir çeşitli alanlarda kullanılmaktadır. Yapılan çalışmaları incelediğimizde gerek klasik görüntü işleme tabanlı gerekse de derin öğrenme tabanlı süper-çözünürlük çalışmalarında genel geçer bir çözümün olmayıp problem bağımlı çözümler sunulduğu gözlenmiştir. Bu çalışmamızda derin öğrenme tabanlı hazır eğitilmiş EDSR ve DBPN modelleri kullanılarak uydu görüntülerinde süper-çözünürlük çalışmalarının ne kadar başarımlı sergileyeceği incelenmiştir. EDSR ve DBPN hazır eğitilmiş modelleri uydu görüntüleriyle eğitilmemesine rağmen keskin geçişli kabul edilebilir sonuçlar ürettikleri ortaya konmuştur. Derin öğrenme tabanlı süper-çözünürlük modellerinin uydu

görüntüleri kullanarak eğitilmesiyle hem objektif değerlendirmelerde hem de görsel değerlendirmelerde daha iyi sonuçların alınabileceği öngörülmektedir. Bununla birlikte uydu görüntülerinin RGB bantlarının haricinde daha geniş spektral aralığıyla (NIR, SWIR) eğitilmesi, farklı tematik alanlara ilişkin uygulama kapsamının ve bu tematik alanlarda farklı kriterlerin ölçülmesindeki hassasiyetlerin artmasına imkan sağlayabilecektir. Bu bağlamda gelecek çalışmalarımız için çeşitli uydulardan alınmış görüntülerle beslenecek derin öğrenme tabanlı bir model geliştirilmesi düşünülmektedir.

## KAYNAKLAR (REFERENCES)

- [1] Gao, S., Gruev, V., Bilinear and bicubic interpolation methods for division of focal plane polarimeters. *Optics Express*, 19 (27), (2011) 26161-26173.
- [2] Bareja, M. N., Modi, C. K., An effective iterative back projection based single image super resolution approach. In *2012 IEEE International Conference on Communication Systems and Network Technologies* (2012) 95-99.
- [3] Wang, Z., Chen, J., Hoi, S. C., Deep learning for image super-resolution: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020.
- [4] Anwar, S., Khan, S., Barnes, N., A deep journey into super-resolution: A survey. *arXiv preprint arXiv:1904.07523*, 2019.
- [5] USGS (Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu), <https://earthexplorer.usgs.gov>, [Online], 11.08.2020.
- [6] Avrupa Uzay Ajansı, [www.esa.int](http://www.esa.int), [Online], 28.10.2020.
- [7] Lim, B., Son, S., Kim, H., Nah, S., Mu Lee, K., Enhanced deep residual networks for single image super-resolution. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (2017) 136-144.
- [8] Haris, M., Shakhnarovich, G., Ukita, N., Deep back-projection networks for super-resolution. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2018) 1664-1673.
- [9] Nasrollahi, K., Moeslund, T. B., Super-resolution: a comprehensive survey. *Machine Vision and Applications*, 25(6) (2014) 1423-1468.
- [10] Suganya, P., Mohanapriya, N., Vanitha, A., Survey on image resolution techniques for satellite images. *International Journal of Computer Science and Information Technologies*, 4(6), (2013) 835-838.
- [11] Demirel, H., Anbarjafari, G., Discrete wavelet transform-based satellite image resolution enhancement. *IEEE Transactions on Geoscience and Remote Sensing*, 49(6), (2011) 1997-2004.
- [12] Wang, Z., Bovik, A. C., Sheikh, H. R., Simoncelli, E. P., Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), (2004) 600-612.
- [13] EDSR-PyTorch, <https://github.com/thstkdgus35/EDSR-PyTorch>, [Online], 29.10.2020.
- [14] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q., Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2017) 4700-4708.
- [15] DBPN-PyTorch, <https://github.com/alterzero/DBPN-Pytorch>, [Online], 30.10.2020.
- [16] Bicubic-interpolation, <https://github.com/rootpine/Bicubic-interpolation>, [Online], 29.10.2020.

- [17] Barsi, J.A., Lee, K., Kvaran, G., Markham, B.L., Pedelty, J.A., The Spectral Response of the Landsat-8 Operational Land Imager. *Remote Sensing*, 6, (2014) 10232-10251.
- [18] Landsat 8 (L8) Data Users Handbook. *LSDS-1574 Version 2.0*, USGS –EROS, Sioux Falls, South Dakota, USA, 29 March 2016.
- [19] Bernstein, L.S., et. al., Quick atmospheric correction code: algorithm description and recent upgrades. *Optical Engineering* 51.11 (2012), 111719.
- [20] Laben C.A., Brower, B. V., Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. *US Patent 6,011,875*, 2000.
- [21] Sarp, G., Spectral and spatial quality analysis of pan-sharpening algorithms: A case study in Istanbul. *European Journal of Remote Sensing*, 47(1), (2014) 19-28.
- [22] Maruer, T., How To Pan-Sharpen Images Using The Gram-Schmidt Pan-Sharpen Method-A Recipe. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, (2013) 239-244.
- [23] L3harrisGeospatial, <https://www.l3harrisgeospatial.com/docs/GramSchmidtSpectralSharpening.html>, [Online], 28.10.2020.
- [24] Hore, A., Ziou, D., Image quality metrics: PSNR vs. SSIM. In *2010 20th International Conference on Pattern Recognition* (2010) 2366-2369.
- [25] Wang, Z., Bovik, A. C., A universal image quality index. *IEEE Signal Processing Letters*, 9(3), (2002) 81-84.
- [26] Sheikh, H. R., Bovik, A. C., Image information and visual quality. *IEEE Transactions on Image Processing*, 15(2), (2006) 430-444.