

UYDU GÖRÜNTÜLERİNİN İYİLEŞTİRİLMESİNDE GELENEKSEL VE DERİN ÖĞRENMEYE DAYALI İKİ YÖNTEMİN KARŞILAŞTIRILMASI

Nuri Erkin ÖÇER¹, Fırat ERDEM², Dilek KÜÇÜK MATCI³, Resul ÇÖMERT³, Gordana KAPLAN⁴, Uğur AVDAN⁴

¹Arş. Gör. Dr., Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, neocer@eskisehir.edu.tr

²Doktora öğrencisi, Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, firaterdem@eskisehir.edu.tr

³Dr. Öğretim Üyesi, Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, dkmatici/romert@eskisehir.edu.tr

⁵Doç. Dr., Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, gkaplan/ uavdan @eskisehir.edu.tr

ÖZET

Süper çözünürlük, çeşitli yollarla görüntü çözünürlüğünü artırmayı amaçlayan ve son yıllarda derin öğrenme alanındaki gelişmelerle beraber daha iyi sonuçların elde edildiği bir görüntü iyileştirme yöntemidir. Keşif-gözetleme, nesne tespiti, çeşitli tıp uygulamaları gibi birçok alanda kendine uygulama sahası bulan bu yöntemle düşük çözünürlüklü görüntülerden daha fazla bilgi çıkarımı yapmak mümkün hale gelmektedir. Görüntü iyileştirme işlemi geleneksel yollarda interpolasyon gibi matematiksel tahminleme yöntemleriyle başarılmaya çalışılırken derin öğrenmeye dayalı modeller bunu çeşitli Konvolüsyonel Sinir Ağı mimarilerini etiketlenmiş verilerle beraber kullanarak gerçekleştirmektedir. Bu çalışmada yaklaşık 3 metre yersel çözünürlüğe sahip 8-bitlik PlanetScope uydu görüntüleri biri geleneksel biküçük interpolasyon, diğeri derin öğrenmeye dayalı ESPCN (Efficient Sub-Pixel Convolutional Neural Network) modelleri kullanılarak iyileştirilmiş ve sonuçlar PSNR (Peak Signal to Noise Ratio) değerleri cinsinden karşılaştırılmıştır. ESPCN'nin eğitiminde farklı veri setleri kullanılmış ve neticeye etkisi gözlenmiştir. Elde edilen sonuçlara göre; eğitimde veri sayısını artırmanın ve eğitim verisi türünün test verisiyle benzer olmasının sonuçları olumlu etkilediği ve ayrıca her ne kadar farklı türde ve az sayıda veriyle eğitilmiş olsa bile ESPCN yönteminin geleneksel biküçük interpolasyona göre daha iyi sonuçlar ürettiği ortaya konulmuştur.

Anahtar Sözcükler: derin öğrenme, görüntü iyileştirme, süper çözünürlük, uzaktan algılama.

ABSTRACT

COMPARISON OF TWO METHODS BASED ON TRADITIONAL AND DEEP LEARNING IN ENHANCING SATELLITE IMAGES

Super resolution is an image enhancement method that aims to increase the image resolution in various ways and has achieved better results with the developments in the field of deep learning in recent years. With this method, which finds application in many fields such as reconnaissance-surveillance, object detection, and various medical applications, it becomes possible to extract more information from low-resolution images. While the image enhancement process is tried to be achieved with mathematical prediction methods such as interpolation in traditional ways, deep learning-based models do this by using various Convolutional Neural Networks architectures together with labeled data. In this study, 8-bit PlanetScope satellite images with a spatial resolution of approximately 3 meters was enhanced using a) a traditional one, e.g. bi-cubic interpolation and b) ESPCN (Efficient Sub-Pixel Convolutional Neural Network) model and the results were compared in terms of PSNR (Peak Signal to Noise Ratio) values. Different data sets were used in the training of ESPCN and its effect on the result was observed. According to the results obtained; It has been revealed that increasing the number of data in training and the training data type being similar to the test data affect the results positively and the ESPCN method produces better results than traditional bicubic interpolation, even if it is trained with different types and few data.

Keywords: deep learning, image enhancement, super resolution, remote sensing.

1. GİRİŞ

Hemen her alanda olduğu gibi uzaktan algılama uygulamalarında da eldeki teknik imkanların sağladığı en iyi veriler kullanılarak çeşitli çıkarımlar yapılmaya çalışılmaktadır, zira çıkarım başarısı ve sınırları veri niteliğine bağlıdır. Verinin görüntü olduğu uygulamalarda görüntünün mekânsal ve spektral çözünürlüğü bu sınırları belirlemektedir. Örneğin, çözünürlük arttıkça daha küçük ve ayırt edilmesi zor nesneler tespit edilebilir hale gelirken tersi durumdaysa aynı nesneler gözden kaçabilmektedir. Ne var ki çoğu zaman daha nitelikli veriye ulaşmak mümkün olmamakta bu sebeple eldeki veriyi iyileştirip geliştirerek mevcut içerikten daha fazla bilgi çıkarmak gerekmektedir. Buna yönelik olarak orijinal görüntünün kalitesini yükseltmek ve bilgi içeriğinden daha fazla faydalanmak üzere çeşitli görüntü iyileştirme yöntemleri geliştirilmiştir. Bunlardan biri, süper çözünürlük (super resolution - SR) olarak tanımlanan, düşük çözünürlüklü bir görüntüden daha yüksek çözünürlüklü görüntünün oluşturulması işlemidir. Öncül SR çalışmalarında çoğunlukla interpolasyon gibi geleneksel matematiksel tahminleme yöntemleri kullanılmış (Patil ve Bormane, 2007) ve bunlar uzaktan algılamada da kendine uygulama sahaları bulmuştur (Babawuro ve Beiji, 2012;

Titus ve Geroge, 2013). Bununla beraber yakın zamanda şahit olduğumuz bilgisayarlı görme ve derin öğrenme alanlarındaki gelişmelerle beraber, görüntü iyileştirmede de çeşitli Konvolüsyonel Sinir Ağı mimarilerinden ve etiketli verilerden faydalanılarak bu görevin bir makine tarafından öğrenilip uygulanabilmesi mümkün hale gelmiştir.

Son yıllarda derin sinir ağlarına dayalı SR modelleri hesaplama performansı ve doğrulukları açısından süper çözünürlüklü görüntülerin oluşturulmasında büyük başarı elde etmişlerdir. Süper Çözünürlük Konvolüsyonel Sinir Ağı (Super-Resolution Convolutional Neural Network - SRCNN) (Dong vd., 2015) ve Çok Derin Süper Çözünürlük (Very Deep Super Resolution - VDSR) (Kim vd., 2016) gibi konvolüsyonel sinir ağlarına dayalı SR yaklaşımları; Süper Çözünürlük GAN (Super Resolution GAN - SRGAN) (Ledig vd., 2017) gibi üretken çekışmeli ağ SR yaklaşımları ve verimli piksel-altı konvolüsyonel sinir ağı SR yaklaşımı (Efficient Sub-pixel Convolutional Neural Network - ESPCN) (Shi vd., 2016) bunlardan bazılarıdır.

SRCNN ve VDSR gibi yaklaşımlar düşük çözünürlüklü görüntüyü istenen boyutlara örneklemek için ağıdaki işlem sürecinin öncesinde veya başlangıcında görüntü üzerinde interpolasyona başvurduğundan ağıdaki öğrenilebilir parametre sayısının artmasına yol açmakta bu da hesaplama karmaşıklığını ve gereken bellek miktarını artırmaktadır. Bu sorunu gidermek üzere CNN ağına verimli bir piksel-altı konvolüsyon katmanının eklendiği ESPCN yaklaşımı önerilmiştir. Çözünürlüğün ağıdaki son katmanda artırıldığı ESPCN'de, ağ düşük çözünürlüklü görüntüyle beslendiğinden interpolasyon yöntemini kullanmaya gerek kalmamakta bu sayede ağ daha iyi bir öğrenme yeteneğine sahip olmaktadır. Girdi boyutu daha küçük olduğundan özellik çıkarımı yapmak için ağıda daha küçük çekirdek boyutuna sahip filtreler kullanılabilir. Böylece hesaplama karmaşıklığı ve gerekli bellek miktarı azalmakta ve verimlilik artmaktadır. ESPCN, yapılan çalışmalarda çeşitli görüntü tipleri için başarılı iyileştirme performansları ortaya koymuştur (Talab vd., 2019; Xu vd., 2020).

Bu çalışmada çözünürlüğü düşürülmüş PlanetScope uydu görüntülerini iyileştirme görevi için biri geleneksel biküçük interpolasyon, diğeri derin öğrenme temelli ESPCN (Efficient Sub-Pixel Convolutional Neural Network) modellerinin performanslarının karşılaştırılması ve ayrıca ESPCN'nin farklı eğitim setlerine vereceği cevabın araştırılması amaçlanmıştır.


2. MATERYAL VE METOD

Çalışmadaki test verileri mekânsal çözünürlüğü yaklaşık 3 metre olan 80×80 piksel boyutundaki 8-bitlik 100 adet uydu görüntüsüdür. Bu görüntü parçaları, ortorektifiye edilmiş, tam çerçeve PlanetScope ürünlerinden türetilmişlerdir. Amerika Birleşik Devletleri'nin Kaliforniya şehrinin San Francisco Körfezi ve San Pedro Körfezi civarından alınan bu görüntüler açık kaynaktan (Rhammel, 2018) temin edilmiştir. Toplam 4000 RGB görüntünün yer aldığı bu veri setindeki kalan 3900 görüntü ESPCN modelinin eğitiminde ve doğrulanmasında kullanılmıştır. Kullanılan örnek bir görüntü Şekil 1'de gösterilmektedir.

Çalışmada ilk önce bu görüntülerin boyutları biküçük interpolasyonla 20×20 piksele indirgenmiş yani çözünürlüğü dörtte birine düşürülmüştür, ardından bu yeni görüntüye; a) tekrar biküçük interpolasyon ve b) ESPCN yöntemleri uygulanarak çözünürlük orijinal haline çıkarılmıştır. İyileştirilen görüntüler sonrasında referans görüntüyle karşılaştırılarak PSNR değerleri hesaplanmıştır. İzlenen yöntem Şekil 2'de özetlenmiştir.




Şekil 1. Çalışmada kullanılan, 80×80 piksel boyutundaki 8-bitlik PlanetScope uydu görüntüsü parçası.



Şekil 2. Çalışmada izlenen yöntemin özet şeması.

2.1. Biküçük İnterpolasyon

Çalışmada kullanılan yöntemlerden biri biküçük interpolasyondur. Bu yöntemde bir görüntüdeki piksel sayısı matematiksel bir ara değer kestirimiyle artırılmaktadır (Gao ve Gruev, 2011). Yöntemde bir $f(x,y)$ fonksiyonunun tanım kümesi içerisindeki herhangi bir (x, y) noktasındaki değeri, en yakın 16 örnekleme noktasının ağırlıklı ortalamasından faydalanılarak elde edilmektedir (Şekil 3). Üçüncü dereceden bir polinom olarak ele alınan bu fonksiyonla aşağıdaki denklem aracılığıyla dört köşe nokta arasında bir yüzey (interpolasyon yüzeyi) oluşturulmaktadır.




Şekil 3. Biküçük interpolasyonda fonksiyonun bir (x, y) noktasındaki değeri (kırmızı noktadaki değeri), en yakın 16 örnekleme noktasının (siyah noktadaki değerlerin) ağırlıklı ortalamasından faydalanılarak elde edilmektedir.

$$f(x,y) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij} x^i y^j$$

Bu denklemdeki fonksiyonun (x, y) 'deki değerini hesaplamak için belirlenmesi gereken 16 a_{ij} katsayısının dördü, tahmin noktasına en yakın dört köşedeki yoğunluk değerleriyken; sekizi yatay ve dikey yöndeki uzaysal türevden, dört katsayı ise diyagonal türevlerden belirlenmektedir. Böylelikle bir (x, y) noktasındaki fonksiyon değeri (örneğin piksel yoğunluğu) kestirilmiş olmaktadır. Bu yolla, 20×20 piksellik, 8-bit derinliğindeki görüntü içerisinde ilave 6000 noktada daha piksel yoğunlukları tahminlenerek $4^2=16$ kat daha yüksek veri yoğunluğundaki yeni 80×80 piksellik görüntü oluşturulmaktadır. Bu işlem Nvidia GTX 1080Ti ekran kartına ve 128 Gb dahili hafızaya sahip Intel i7 6850K CPU'lu bir bilgisayarda yaklaşık 2ms'de tamamlanmaktadır.

2.2. ESPCN

Çalışmada görüntü çözünürlüğünü artırmada kullanılan diğer yöntem ESPCN'dir. Bu modelin ağ yapısı Şekil 4'te gösterilmektedir. Toplam L katmandan oluşan ağın ilk L-1 katmanı girdi görüntüsünün özellik haritalarını çıkaran konvolüsyon katmanları ve son katman görüntü çözünürlüğünü istenen üst ölçeğe yükselten piksel-altı konvolüsyon katmanıdır.



Şekil 4. ESPCN'de düşük çözünürlüklü görüntüden yüksek çözünürlüklü görüntüyü oluşturmak üzere, özellik haritalarının çıkarılması için konvolüsyon katmanları ve bunları takiben görüntünün çözünürlüğünü yükselten bir piksel-altı konvolüsyon katmanı yer almaktadır. (Shi vd., 2016).

Kanal sayısı C, genişliği W ve yüksekliği H ile temsil edilmek üzere, $[C, W, H]$ tensörüyle ifade edilen bir girdi görüntüsü ESPCN ağında şu aşamalardan geçmektedir:

1. 64 filtreli ve 5×5 çekirdek boyutuna sahip konvolüsyon katmanı, ardından bir ReLU aktivasyon katmanı,
2. 32 filtreli ve 3×3 çekirdek boyutuna sahip konvolüsyon katmanı, ardından bir ReLU aktivasyon katmanı,
3. $C \times r \times r$ filtreli ve 3×3 çekirdek boyutuna sahip konvolüsyon katmanı (r: yükseltme faktörü), ardından bir ReLU aktivasyon katmanı,
4. Piksel-altı karıştırma (shuffle) fonksiyonunun uygulanarak görüntünün istenen $[C, r \times W, r \times H]$ boyutuna getirilmesi, ardından bir sigmoid aktivasyon katmanı.

Böylece hedeflenen; C kanal sayısına, $r \times W$ 'lik genişliğe, $r \times H$ 'lik yüksekliğe sahip yüksek çözünürlüklü çıktı görüntüsü oluşturulmuş olunur. Klasik yaklaşımlarda interpolasyonun yaptığı iş ESPCN'de ağ tarafından otomatik olarak öğrenilerek konvolüsyon katmanlarında dolaylı olarak ifa edilmektedir.

ESPCN'nin eğitimi orijinal çözünürlükteki görüntüler ve bunların çözünürlüğü düşürülmüş halleri kullanılarak gerçekleştirilmektedir. Eğitimde orijinal görüntüler yer gerçeği olarak kabul edilmekte ve oluşturulan SR görüntülerinin bunlardan sapmaları ortalama karesel hata fonksiyonu (mean squared error - MSE) ile hesaplanmaktadır. MSE kayıp fonksiyonu piksel bazında şöyle hesaplanmaktadır:

$$l(W_{1:L}, b_{1:L}) = \frac{1}{r^2 H W} \sum_{x=1}^{rW} \sum_{y=1}^{rH} (I_{x,y}^{HR} - f_{x,y}^L(I^{LR}))^2$$

Burada I^{HR} , veri setindeki her bir orijinal görüntüyü; I^{LR} , her bir çözünürlüğü düşürülmüş görüntüyü; r, yükseltme faktörünü; H, görüntünün yüksekliğini; W görüntünün genişliğini; $W_{1:L}$ tüm öğrenilebilir ağ ağırlıklarını ve $b_{1:L}$ tüm öğrenilebilir biasları temsil etmektedir. Model, eldeki veriyle bir optimizasyon yöntemi kullanılarak bu kayıp fonksiyonunu minimize edecek şekilde eğitilmektedir.

2.2.1. Eğitim Setleri

Bu çalışmada ESPCN modeli üç farklı veri seti kullanılarak eğitilmiştir. Veri sayısı ve türü yönünden farklılık arz eden bu setlere dair bilgiler Tablo 1’de verilmiştir.

	Görüntü tipi	Eğitim veri sayısı	Validasyon veri sayısı
Set-1	Doğal	400	100
Set-2	Uydu	400	100
Set-3	Uydu	2930	970

Tablo 1. ESPCN modelinin eğitiminde kullanılan görüntü tipleri ve sayıları.

Set-1, Berkeley Segmentation Data Set 500 (BSDS500) (Arbelaez vd., 2010) veri seti olup kontur tespiti ve doğal kenar algılamayı değerlendirmek için tasarlanıp oluşturulmuştur. BSDS500’de obje sınırları etiketlenmiş 500 doğal görüntü yer almaktadır. Çalışmada bu görüntülerden 400’ü eğitim için, 100’ü doğrulama için kullanılmıştır. Bu veri setinde herhangi bir uydu görüntüsü bulunmamaktadır, örnek bir görüntü Şekil 5’te gösterilmiştir. Çalışmanın bu veri setiyle alakalı kısmında model, bu görüntülerden 80×80 piksellik parçalar kesilerek beslenmiştir.




Şekil 5. BSDS500’de yer alan bir doğal görüntü.

Set-2, test verileriyle aynı kaynaktan (Rhammel, 2018) alınmış görüntülerle oluşturulmuş olup veri sayısı Set-1’le aynı olacak şekilde belirlenmiştir. Set-3 ise (Rhammel, 2018)’deki 4000 veriden test için kullanılan 100 görüntü haricindeki diğer tümü kullanılarak oluşturulmuştur.

2.2.2. Modelin Eğitimi

Bu çalışmada ESPCN yöntemi, (Long, 2020) tarafından sağlanan, Keras ve Tensorflow kütüphanelerini kullanan kod aracılığıyla çalıştırılmıştır. Modeli yukarıdaki veri setleriyle eğitmek için Adam optimizasyon yöntemi ve 0.0005’lik bir öğrenme oranı kullanılmıştır. Her bir set için veriler 8’li yığınlar halinde modele girilerek eğitim 200 devirde tamamlanmıştır. Şekil 1’deki görüntüden türetilen düşük çözünürlüklü görüntünün çeşitli eğitim devirlerinin sonrasındaki halleri Şekil 6’da gösterilmektedir. Model eğitimi, Set-1 ve Set-2 kullanıldığında yaklaşık 30 saniye sürerken Set-3 için yaklaşık 200 saniyede tamamlanmaktadır. Eğitimden sonra her bir test görüntüsünün işlenmesi ise ortalama 10ms’yi almaktadır.



Şekil 6. Modelin eğitim sürecinde bir girdi görüntüsünün çeşitli eğitim devirlerinin ardından çıktı halleri.

2.3. Değerlendirme Metriği: PSNR

İki yöntem tarafından üretilen iyileştirilmiş görüntülerin her bir pikseli orijinal görüntülerin pikselleriyle kıyaslanarak sonuçlar PSNR (Peak Signal to Noise Ratio - Doruk Sinyal-Gürültü Oranı) değerleri cinsinden ifade edilmiştir. PSNR, bir sinyalin olası en yüksek gücü ile gürültüsünün gücü arasındaki oranın logaritmik ifadesidir ve bir görüntünün

temsiline görüntünün orijinaline göre kalitesini ölçmekte kullanılmaktadır. PSNR ne kadar yüksek olursa, sıkıştırılmış veya yeniden oluşturulmuş görüntünün kalitesinin o kadar iyi olduğu anlamına gelmektedir. Matematiksel olarak şöyle tanımlanmaktadır:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right)$$

Burada MAX_I , görüntünün mümkün olan en yüksek piksel değeri olup çalışmamızdaki gibi 8-bitlik bir görüntü için bu 255'tir. Bu denklemdeki karesel hata fonksiyonu (MSE) ise karşılaştırılan iki görüntünün her bir pikseli için her bir renk kanalındaki (c) piksel değerlerinin farklarının karelerinin toplamının toplam piksel sayısı çarpı kanal sayısına oranıdır ve şöyle formülize edilmektedir:

$$MSE = \frac{1}{3HW} \sum_{c=0}^2 \sum_{i=0}^{W-1} \sum_{j=0}^{H-1} [I^{HR}(i,j) - I^{LR}(i,j)]^2_c$$


3. BULGULAR VE TARTIŞMA

Yukarıda ifade edilen yöntemler test veri setindeki 100 görüntüye uygulanarak görüntü çözünürlükleri 20×20 pikselden 80×80 piksele çıkarılmıştır. Her bir yöntemle iyileştirilen bu verilerin orijinalleriyle kıyaslanmasıyla elde edilen ortalama PSNR değerleri ve bu değerlere karşılık gelen piksel başına sapmalar Tablo 2'de verilmiştir. Bu test seti için en iyi sonuçları üreten model, eğitiminde Set-3'ün kullanıldığı ESPCN olmuştur. Orijinal görüntüden piksel başına yaklaşık 7,5'lik bir sapmayla sonuçlar üreten bu modelin, eğitiminde kullanılan, diğerlerine göre fazla sayıdaki verinin avantajını kullanmış olduğu görülmektedir. Diğer yandan, veri sayıları aynı olan Set-1 ve Set-2 ile eğitilmiş ESPCN, içerisinde test veri setindeki gibi uydu görüntülerinin yer aldığı Set-2 aracılığıyla eğitildiğinde daha başarılı bir performans göstermiştir. Çözünürlüğün biküçük interpolasyonla artırıldığı görüntüler ise orijinallerden en yüksek sapmayı göstermişlerdir. Biküçük interpolasyonla karşılaştırıldığında Set-3'le eğitilmiş ESPCN, orijinal görüntüden piksel başına yaklaşık yüzde 20 daha az sapma göstermiştir.

	ESPCN(Set-1)	ESPCN(Set-2)	ESPCN(Set-3)	Biküçük
Ortalama PSNR (dB)	29,7004	30,2769	30,6287	28,6701
Piksel başına sapma	8,3468	7,8108	7,5008	9,3980

Tablo 2. Çalışmada kullanılan yöntemlerin 100 test verisi için ürettiği sonuçların ortalama PSNR ve piksel başına sapma değerleri.

Test veri setinde yer alan altı farklı örnek görüntü için çalışmada kullanılan yöntemlerin ürettiği sonuçlar Şekil 7'de gösterilmiştir. Bir geminin yer aldığı en üstteki satırdaki ve üstten üçüncü satırdaki köprü örnekleri için en iyi sonucu Set-2 ile eğitilmiş ESPCN vermiştir. İçeriğin karmaşık olduğu diğer örneklerde ise en iyi sonuçlar Set-3 ile eğitilmiş ESPCN tarafından üretilmiştir. Özellikle üstten dördüncü satırdaki kompleks yapıdaki büyük binanın yer aldığı görüntüde bu yöntem diğerlerine göre ciddi bir iyileştirme performansı göstermiştir. Bu örnekler arasında biküçük yöntemin diğerlerine üstünlük sağladığı tek görüntü, içerisinde hiç bir objenin yer almadığı bir deniz enstantanesi olmuştur.



Şekil 7. Test veri setinde yer alan altı farklı orijinal görüntü ve bu görüntülerin düşük çözünürlüklü versiyonlarının girdi olarak kullanılmasıyla modeller tarafından üretilmiş olan çıktı görüntüleri.

4. SONUÇ

Görüntü iyileştirme yöntemlerini kullanarak uydu görüntülerinde var olan bilgiden daha fazla fayda sağlamak mümkündür. Geleneksel yöntemlerle belirli seviyelere ulaşılan bu işlemin, büyük miktardaki veriden faydalanarak eğitilen konvolüsyonel ağlar aracılığıyla daha başarılı olduğu doğal görüntüler için ortaya konulmuştur. Bu çalışmada ise ESPCN yöntemiyle görüntü iyileştirme işlemi uydu görüntülerine uygulanmıştır. Bu modelin eğitiminde farklı türde ve sayıda veriler kullanılarak bunların sonuçlar üzerine etkisi PSNR parametresi vasıtasıyla gözlenmiştir. Elde edilen sonuçlara göre; (1) eğitimde veri sayısını artırmanın üretilen sonuçların doğruluklarını artırdığı, (2) eğitim verisi türünün test verisiyle benzer olmasının sonuçları olumlu etkilediği ve (3) son olarak her ne kadar farklı türde ve az sayıda veriyle eğitilmiş de olsa ESPCN yönteminin geleneksel biküzik interpolasyona göre daha iyi sonuçlar ürettiği ortaya konulmuştur. Geleceğe dönük olarak, bu çalışmada kullanılan modeli, sayısı doğal veya sentetik yollarla artırılmış verilerle eğiterek elde edilecek sonuçların ne ölçüde iyileştirilebileceğinin belirlenmesi hedeflenmektedir.

KAYNAKLAR

Arbelaez, P., Maire, M., Fowlkes, C., & Malik, J. (2010). Contour detection and hierarchical image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 33(5), 898-916.

Babawuro, U., & Bei, Z. (2012). Multi-resolution Satellite Imagery Rectification using Bi-linear Interpolation Method for Quantitative Analysis. *International Journal of Digital Content Technology and its Applications*, JDCTA, Volume6, (2).

Dong, C., Loy, C. C., He, K., & Tang, X. (2015). Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307.

Gao, S., & Gruev, V. (2011). Bilinear and bicubic interpolation methods for division of focal plane polarimeters. *Optics express*, 19(27), 26161-26173

Haldar, S. K. (2018). Mineral exploration: principles and applications. *Elsevier*.

Kim, J., Lee, J. K., & Lee, K. M. (2016). Accurate image super-resolution using very deep convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1646-1654).

Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4681-4690).

Long, X. (2020). https://keras.io/examples/vision/super_resolution_sub_pixel/, erişim tarihi 14 Eylül 2022.

Patil, V. H., & Bormane, D. S. (2007). Interpolation for super resolution imaging. In *Innovations and Advanced Techniques in Computer and Information Sciences and Engineering* (pp. 483-489). Springer, Dordrecht.

Rhammel, A. (2018). <https://www.kaggle.com/datasets/rhammell/ships-in-satellite-imagery>, erişim tarihi 14 Eylül 2022.

Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., ... & Wang, Z. (2016). Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1874-1883).

Talab, M. A., Awang, S., & Najim, S. A. D. M. (2019, June). Super-low resolution face recognition using integrated efficient sub-pixel convolutional neural network (ESPCN) and convolutional neural network (CNN). In *2019 IEEE international conference on automatic control and intelligent systems (I2CACIS)* (pp. 331-335). IEEE.

Titus, J., & Gero, S. (2013). A comparison study on different interpolation methods based on satellite images. *International Journal of Engineering Research & Technology*, 2(6), 82-85.

Xu, M., Wang, D., & Du, X. (2020, February). A video frame resolution and frame rate amplification method with optical flow method and espcn model. In *Proceedings of the 2020 3rd International Conference on Image and Graphics Processing* (pp. 91-95)