

## Sentinel-2 Uydu Görüntüleri için Evrişimli Otokodlayıcı Sinir Ağı ile Süper Çözünürlük Yaklaşımı

### *Super Resolution Approach with Convolutional Autoencoder Neural Network for Sentinel-2 Satellite Imagery*

Ahmet Ertuğrul Arık<sup>1\*</sup>, Reha Paşaoğlu<sup>1</sup>, Nuri Emrahaoğlu<sup>1</sup>

<sup>1</sup>Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana /Türkiye.

#### ARAŞTIRMA MAKALESİ

##### \*Sorumlu yazar:

Ahmet Ertuğrul Arık  
ertugrularik@hotmail.com

doi: 10.48123/rsgis.1254716

##### Yayın süreci

Geliş tarihi: 22.02.2023

Kabul tarihi: 04.09.2023

Basım tarihi: 28.09.2023

#### Özet

Makalede, uydu görüntülerinin çözünürlüğünü arttırmak için SEN-2\_CAENET adında evrişimli otokodlayıcı temelli yeni bir süper çözünürlük derin öğrenme modeli sunulmaktadır. Yapay sinir ağları, son yıllarda uydu görüntülerinde uzamsal çözünürlük artırma konusunda önemli bir rol oynamaktadır. Özellikle, geliştirilebilir yapay sinir ağları, verilen girdi verilerine benzer ama tamamen farklı girdi verilerine uygulandığında da doğru çıktı verileri elde edilebilir. Bu özellik, yapay sinir ağlarının uzamsal çözünürlük artırma işlemlerinde etkin bir şekilde kullanılmasını sağlar. Makalede, Sentinel-2 uydu görüntüleri için kullanılan bir otokodlayıcı temelli derin sinir ağı modelinin nasıl uzamsal çözünürlük artırma işlemlerinde kullanılabileceği açıklanmaktadır. Bu model, kullanılan veriler ve eğitim yöntemleri ile görüntülerin detaylarının daha iyi görülebilmesini ve bu sayede görüntülerin daha etkili bir şekilde analiz edilebilmesini mümkün kılmaktadır. Testlerimizde, Sentinel-2 uydu görüntüleri üzerinde uyguladığımız SEN-2\_CAENET modelinin performansını PSNR, MSE ve SSIM metrikleri kullanarak ölçtük. Elde ettiğimiz bulgular, SEN-2\_CAENET'in literatürde önemli bir konuma sahip olan SRCNN sinir ağından daha yüksek başarı oranlarına ulaştığını göstermiştir.

**Anahtar kelimeler:** Yapay sinir ağları, Otokodlayıcılar, Görüntü işleme, Süper çözünürlük Uzaktan algılama

#### Abstract

In the article, a new super resolution deep learning model based on convolutional autoencoder named SEN-2\_CAENET is presented to increase the resolution of satellite images. Artificial neural networks have been playing an important role in increasing the resolution of satellite images in recent years. In particular, when generalizable neural networks are applied to similar but completely different input data, accurate output data can be obtained. This feature enables artificial neural networks to be used effectively in resolution enhancement processes. The article explains how an autoencoder-based model used for Sentinel-2 satellite images can be used for resolution enhancement. This model makes it possible to see the details of the images better with the data and training methods used, and thus to analyze the images more effectively. In the tests applied to Sentinel-2 satellite images, SEN-2\_CAENET, which we created in PSNR, MSE and SSIM metrics, received more successful results than the SRCNN neural network, which has an important place in the literature.

**Keywords:** Artificial neural network, Autoencoders, Super resolution, Image processing, Remote sensing

## 1. Giriş

Günümüzde, uydu görüntüleri coğrafi bilgi sistemleri (CBS), hava durumu tahminleri, oşinografik ölçümler, tarımsal faaliyetler, jeolojik araştırmalar ve yerleşim yönetimi gibi alanlarda yaygın olarak kullanılmaktadır. Ancak, uydu görüntülerinin çözünürlüğü sınırlıdır ve bu, bilgi toplama ve anlamlandırma sürecinde sınırlamalar getirmektedir.

Yapay sinir ağları, son yıllarda uydu görüntülerindeki uzamsal çözünürlük artırma alanında önemli bir rol oynamaktadır ve verilen girdilere dayanarak sınıflandırma, tahminleme ve diğer işlemler yapılarak, uydu görüntülerinin çözünürlüğünü artırılmaktadır. Yapay sinir ağları özellikle genelleştirme yeteneğine sahiptir, bu da verilen girdilere benzer ama farklı girdi verilerine uygulandığında da doğru çıktılar üretmesini mümkün kılar (Liu vd., 2020). Bu özelliği, yapay sinir ağlarının uydu görüntülerindeki uzamsal çözünürlük artırma işlemlerinde etkin bir şekilde kullanılmasını sağlar.

Dong vd., (2015) tarafından yapılan çalışmada çalışmada evrişimli derin sinir ağı kullanarak süper çözünürlük tekniklerini kullanmışlardır. SRCNN olarak adlandırılan sinir ağı o döneme kadarki mevcut interpolasyon yöntemlerinden daha başarılı sonuçlar elde etmiştir. Szegedy vd., (2015) tarafından yapılan bir çalışmada, 2014 yılı "ImageNet Large-Scale Visual Recognition Challenge" (ILSVRC14) yarışmasında sınıflandırma ve tespit problemlerinde güncel sonuçları elde etmeyi amaçlayan "Inception" adlı bir derin evrişimli sinir ağı mimarisi sunulmuştur. Bu mimarinin önemli bir özelliği, sinir ağının eğitim sürecinde ihtiyaç duyduğu hesaplama gücünün daha verimli kullanılmasıdır. Sinir ağını genişletirken ağın derinliğini ve genişliğini arttırmayı amaçlayan tasarım, hesaplama gücü ihtiyacını azaltmıştır. Liu vd., (2018) tarafından yapılan bir çalışma, derin artımlı (residual) yapay sinir ağlarının kullanımıyla pankromatik uydu görüntülerinde uzamsal çözünürlük artırma ve yapay renklendirme sürecini incelemiştir. Bu çalışma, yapay sinir ağlarının uydu görüntülerinin çözünürlüğünü yükseltirken aynı zamanda görüntülerin kalitesini de koruduğunu göstermiştir. Dong vd. (2016) tarafından yapılan bir başka çalışma ise, SRCNN sinir ağlarının uydu görüntülerinde uzamsal çözünürlük artırma sürecini hızlandırdığını göstermiştir.

Galar vd. (2020), kullandıkları SRCNN algoritması görüntülerin çözünürlüğünü bir noktaya kadar yükseltmiştir. Lanaras vd. (2018) ise, DSEN2 adında sentinel-2 verileri ile eğitilen bir derin sinir ağı algoritması, görüntülerin detaylarının daha iyi görülebilmesini sağladığını ve bu sayede görüntülerin daha etkili bir şekilde analiz edilebilmesini mümkün kıldığını ileri sürmektedir. Romero vd. (2020), RS-ESRGAN diye isimlendirilen ESRGAN derin sinir ağı yöntemini esas alan bir süper çözünürlük tekniği geliştirdiklerini ve bu yöntemle uydu görüntülerinde çözünürlüğün yükseldiğini, bu sayede daha ayırt edilebilen görüntüler elde edildiğini belirtmişlerdir. Salgueiro vd. (2020), yaptıkları çalışmada Residual network temelli Sen2-RDSR olarak isimlendirilen bir sinir ağı modeli ile Sentinel-2 uydu görüntüsü üzerinde 60m ve 20m bantlarında çözünürlüğü yükselttiklerini belirtmişlerdir. Zhang vd. (2019) ise, yaptıkları çalışmada Super-Resolution for Multispectral Multiresolution Estimation) algoritmasını kullanarak bitki sağlığı açısından önemli olan kızılötesi bantların çözünürlüğünü yükselttiklerini belirtmişler ve aynı zamanda görüntülerin renk doğruluğunu da artırdığını rapor etmişlerdir. Özellikle, Wang vd. (2022), yaptıkları çalışma ile son yıllardaki derin sinir ağı kullanan süper çözünürlük yöntemlerini incelemiş ve karşılaştırmış, YSA kullanımının uydu görüntülerinde uzamsal çözünürlük artırma işlemini iyileştirme gücüne sahip olduğunu ve daha da ilerleyecek potansiyelin mevcut olduğunu göstermiştir. Pineda vd. (2020) yürüttükleri çalışmada GAN (Generative Adversery Network) yaklaşımı ile daha az sayıda görüntü kümesinin eğitimde kullanılmasıyla Sentinel-2 uydusu görüntülerinde mekânsal çözünürlüğü artırmayı amaçlamışlardır.

Yang vd. (2018) yaptıkları tek görüntü üzerinden derin sinir ağları kullanarak süper çözünürlük üzerine derleme çalışmasında mevcut yöntemleri incelemiş, derin öğrenme algoritmalarını kıyaslamış, mevcut zorluklar ve gelecek trendleri özetlemiştir. Turhan ve Bilge (2019), çalışmalarında, yeni bir yaklaşım olan üretici çekişmeli ağ (GAN) ve Varyasyonel Otokodlayıcı (VAE) ağının bir hibriti olarak, yapay görüntülerle eğitilmeksizin, istenen uzamsal çözünürlükte görüntüler elde etmeyi sağlayan GAN ve VAE modelleri bir arada kullanılarak, VAE/CPGAN adı verilen bir model sunmuşlardır. Cengiz ve Avcı (2021) çalışmalarında sivil ve askeri amaçlı olarak görüntünün çözünürlüğünün önemini vurgulamaktadır. Bu amaçla, uydu görüntüleri üzerinde derin öğrenme tabanlı evrişimsel sinir ağları uygulanmıştır. Üç farklı derin öğrenme mimarisi (DenseNet201, SqueezeNet, Vgg16) test ve eğitim verileri üzerinde uygulanmış ve sonuçlar karşılaştırılmıştır. Sonuç olarak, süper çözünürlük yöntemi sayesinde evrişimsel sinir ağları öğrenme özelliklerinin iyileştiği ve sınıflandırma başarısının en düşük 2,4% ve en yüksek 3,6% oranında arttığı öne sürülmüştür. Dong vd. (2022) çalışmalarında KANET adını verdikleri sinir ağının, evrişim katmanında çerçeve temelli bir süper çözünürlük yaklaşımı benimsemişler ve eğitim görüntülerinin indirgenmesinde gerçek dünya görüntülerine daha yakın görüntüler elde ederek modeli eğittiklerini ifade etmişlerdir. Liu vd. (2022) çalışmasında ise pankromatik görüntülerin spektral ve uzamsal çözünürlüğünü artırmak için, görüntü renklendirme ve süper çözünürlük fikirlerinin birleştirildiği, renk duyarlı bir süper çözünürlüklü ağ tasarımı oluşturmuşlar ve öne sürdükleri sinir ağı yaklaşımı uydu görüntülerinde uzamsal çözünürlük artırma işlemini daha da ilerletebileceğine dair bulgular sunmuştur. Zabalza ve Bernardini (2022) çalışmalarında Sentinel-2 Red-Green-Blue-NIR (RGBN) bantlarının orijinali 10 metre olan çözünürlüğünü 2.5 metreye yükseltmeyi ve böylece oluşan görüntüdeki piksel sayısını 4 kat artırarak görsel kaliteyi ve verinin daha iyi yorumlanmasını sağlamaya çalışmışlardır.

Bu amaçla, Super-Resolution Residual Network (SRResNet) adında bir güncel artıklı öğrenme tabanlı model uygulamışlardır. Modeli, PlanetScope-Sentinel çift görüntüleri kullanarak eğitmişler ve modele Spectral Attention Residual Network (SARNet) adını vererek güncel yöntemlerden daha iyi sonuçlar aldığını öne sürmüşlerdir.

Bu çalışmalar, süper çözünürlük tekniklerinin uydu görüntülerinin çözünürlüğünü yükseltirken aynı zamanda görüntülerin kalitesini ve detaylarını da artırdığını göstermekle birlikte, makine öğrenimi ve bilgisayar görüşü uygulamalarında da yaygın olarak kullanılmaktadır ve bu alanlarda daha doğru tahminler yapılmasına yardımcı olabilmektedir. Ayrıca, süper çözünürlük teknikleri sayesinde uydu görüntülerinin boyutları da azaltılabilmektedir. Bu nedenle, süper çözünürlük teknikleri, uydu görüntülerinin işlenmesi, analizi ve kullanımında önemli bir rol oynayan konudur.

Bu araştırmada, uydu görüntülerinin çözünürlüğünün artırılması amacıyla, son yıllarda özellik çıkarımı, gürültü filtreleme, aykırı durum tespiti ve eksik veri tamamlama gibi pek çok farklı alanda geniş kullanım alanı bulunan Evrişimli Otokodlayıcı Yapay Sinir Ağı modeli kullanılmıştır (Leite vd., 2018).

## 2. Materyal ve Metot

### 2.1. Amaç

Uydu görüntülerinde süper çözünürlük amaçlı sinir ağı için eğitim veri seti hazırlarken, zamansal ve uzamsal çözünürlüğü yüksek, erişimi kolay bir veri kaynağı gerekmektedir. Bu şartları sağlayan Sentinel-2 uyduları veri seti hazırlamak için idealdir.

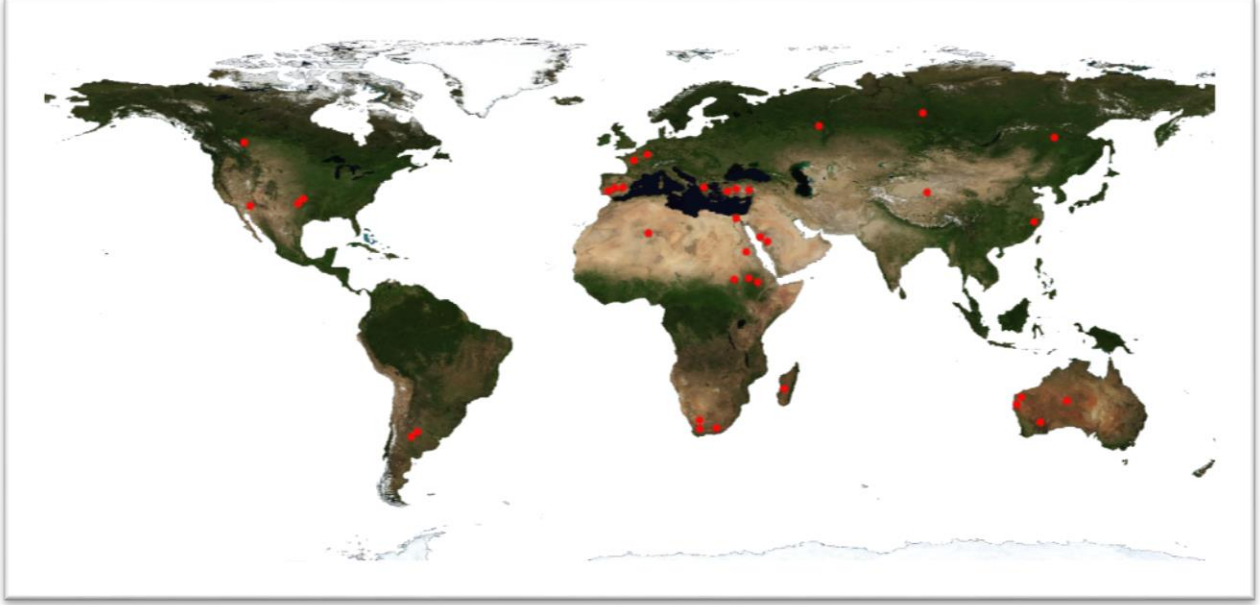
Copernicus Sentinel-2 görevi, 2015'te fırlatılan Sentinel-2A ve 2017'te fırlatılan Sentinel-2B olmak üzere iki uydu kümesini içermektedir. İki uydu, aynı yörüngede 180 derecelik faz açısıyla uçmakta ve yüksek tekrar ziyaret frekansı (yaklaşık 5 gün) sağlamaktadır. Ayrıca, Nadir'den 13 çoklu spektral bantta 3 farklı uzamsal çözünürlükte (10 m, 20 m ve 60 m) görüntüler kaydetme özelliğine sahip Çoklu Spektral Enstrümana (MSI) sahiptirler. Bu enstrüman, görünür ışıktan kısa dalga uzunlukları arasındaki spektral frekansları kapsamaktadır. Teknik detaylar tablo 1'de verilmiştir (ESA, 2023a).

**Tablo 1.** Sentinel-2 için spektral bant özellik tablosu

Sentinel-2 Bantları	Sentinel-2A		Sentinel-2B		Uzamsal Çözünürlük(m)
	Merkezi Dalga Boyu (Nm)	Bant Genişliği (Nm)	Merkezi Dalga Boyu (Nm)	Bant Genişliği (Nm)	
Band 1 – Coastal Aerosol	442.7	21	442.2	21	60
Band 2 – Blue	492.4	66	492.1	66	10
Band 3 – Green	559.8	36	559	36	10
Band 4 – Red	664.6	31	664.9	31	10
Band 5 – Vegetation Red Edge	704.1	15	703.8	16	20
Band 6 – Vegetation Red Edge	740.5	15	739.1	15	20
Band 7 – Vegetation Red Edge	782.8	20	779.7	20	20
Band 8 – NIR	832.8	106	832.9	106	10
Band 8A – Narrow NIR	864.7	21	864	22	20
Band 9 – Water Vapour	945.1	20	943.2	21	60
Band 10 – SWIR – Cirrus	1373.5	31	1376.9	30	60
Band 11 – SWIR	1613.7	91	1610.4	94	20
Band 12 – SWIR	2202.4	175	2185.7	185	20

## 2.2. Çalışma Alanı

Öncelikle derin öğrenme modeli kurmak için dünya üzerinde Tablo 2’de ve şekil 1’de belirtildiği üzere 39 farklı noktadan 10980x10980 boyutunda 13 bant sentinel-2 uydu Seviye 2A görüntüleri alınmıştır.



Şekil 1. Kullanılan çalışma alanları görüntü konumları

Tablo 2. Çalışma alanı görüntü listesi

Uydu	Çok Bantlı Alet	Bölge Kodu (tile number)	Tarih	Saat
S2B	MSIL2A	T36SXJ	12.07.2022	08:26:09
S2A	MSIL2A	T14SND	2.08.2022	17:09:01
S2A	MSIL2A	T14SPE	2.08.2022	17:09:01
S2A	MSIL2A	T37QFG	14.08.2022	07:46:21
S2A	MSIL2A	T37SBC	23.08.2022	08:16:21
S2A	MSIL2A	T31UFQ	25.08.2022	10:36:41
S2A	MSIL2A	T36SXJ	26.08.2022	08:26:21
S2A	MSIL2A	T31TCN	28.08.2022	10:46:31
S2A	MSIL2A	T36PTU	2.09.2022	08:16:21
S2A	MSIL2A	T29SQC	3.09.2022	11:06:31
S2A	MSIL2A	T30SUJ	3.09.2022	11:06:31
S2A	MSIL2A	T37QFF	3.09.2022	07:46:21
S2A	MSIL2A	T30SWJ	10.09.2022	10:56:31
S2A	MSIL2A	T50RQT	10.09.2022	02:35:41
S2B	MSIL2A	T11UPU	26.09.2022	18:51:29
S2A	MSIL2A	T38KNC	5.10.2022	07:12:11
S2A	MSIL2A	T35HLE	6.10.2022	07:58:11
S2A	MSIL2A	T37RDH	6.10.2022	07:58:11
S2A	MSIL2A	T36QXH	9.10.2022	08:08:41
S2A	MSIL2A	T34SEJ	20.10.2022	09:20:31
S2A	MSIL2A	T35SPC	21.10.2022	08:50:11
S2A	MSIL2A	T50JKT	21.10.2022	02:32:51
S2A	MSIL2A	T50KLV	21.10.2022	02:32:51
S2B	MSIL2A	T36SXH	30.10.2022	08:30:09
S2A	MSIL2A	T36PYU	5.11.2022	08:01:21

Tablo 2'nin devamı


Uydu	Çok Bantlı Alet	Bölge Kodu (tile number)	Tarih	Saat
S2A	MSIL2A	T19FCD	30.11.2022	14:07:11
S2A	MSIL2A	T37PCN	2.12.2022	07:53:01
S2B	MSIL2A	T31RGJ	9.12.2022	10:13:19
S2A	MSIL2A	T36RUU	14.12.2022	08:33:41
S2A	MSIL2A	T36SUH	27.12.2022	08:43:51
S2A	MSIL2A	T36SUJ	27.12.2022	08:43:51
S2A	MSIL2A	T35SPC	9.01.2023	08:53:31
S2B	MSIL2A	T12SUC	12.01.2023	18:17:19
S2B	MSIL2A	T20HLH	14.01.2023	14:07:09
S2B	MSIL2A	T20HMJ	14.01.2023	14:07:09
S2B	MSIL2A	T34HDK	15.01.2023	08:22:09
S2B	MSIL2A	T34JDM	15.01.2023	08:22:09
S2B	MSIL2A	T51JUG	15.01.2023	01:56:19
S2B	MSIL2A	T52KEU	16.01.2023	01:27:09

### 2.3. Sınır Ağı Mimarisi

SEN-2\_CAENET olarak isimlendirilen yeni model, Evrişimli Otokodlayıcı Derin Sınır Ağı (Convolutional Autoencoder Neural Network) kullanılarak Tensorflow/Keras kütüphaneleri ve Python programlama dili ile geliştirilmiştir. Modelin temel amacı, düşük çözünürlüklü Sentinel-2 görüntülerinden yüksek çözünürlüklü görüntüler elde etmektir. Modelin mimarisi, giriş katmanı, 3 evrişimli katman, 3 ters evrişimli katman ve çıkış katmanı olmak üzere toplam 8 katmandan oluşmaktadır.

Her evrişimli katman, ReLU (Rectified Linear Unit) aktivasyon fonksiyonu ile birleştirilmiştir ve ardından Yığın Normalleştirme (Batch Normalization) kullanılarak öğrenme sürecini hızlandırılmıştır. Evrişimli katmanlar, özellik haritaları oluşturarak görüntüdeki temel özelliklerin öğrenilmesini sağlar. Ters evrişimli katmanlar ise, özellik haritalarını yükseltmek ve daha büyük boyutlara getirmek için kullanılmaktadır. Bu şekilde, düşük çözünürlüklü giriş görüntülerinden yüksek çözünürlüklü çıktı görüntüleri elde edilir.

Model toplamda 194,433 adet eğitilebilir parametreye sahiptir ve modelin mimarisi Şekil 2'de gösterilmiştir.



Şekil 2. SEN-2\_CAENET Evrişimli Otokodlayıcı Sınır Ağı

Model tanımlandıktan sonra, tek görüntüde süper çözünürlük (Single-Image Super-Resolution) için kullanılmıştır. Bu amaçla, girdi olarak kullanacağımız görüntüleri önceden ayrıntılı bir şekilde ön işleme yapmak gerekmektedir. Bu işlemler arasında kırma ve renk uzayı dönüşümleri yer almaktadır.

## 2.4. Görüntü Ön İşleme

Alınan görüntülerde Snap uygulaması üzerinden bant 2, bant 3 ve bant 4 olmak üzere ayrı ayrı subset operatörü kullanılarak yeniden örneklenmiştir (ESA, 2023b). 12 bitlik görüntüler, OpenCv kütüphanesinden yararlanılarak normalizasyon yöntemiyle radyometrik çözünürlük azaltılarak 8 bit'lik görüntülere dönüştürülmüştür.

Derin sinir ağına verilen küçük görüntü parçalarının işlenmesi sırasında, evrişim katmanlarının yapısından kaynaklanan dış çerçevedeki bozulmalar meydana gelmektedir. Bu bozulmaları ortadan kaldırmak için, her bir görüntünün 32 pikselinin üst üste konulması ve bir örtüşme bölgesi oluşturulması tercih edilmiştir. Bu örtüşme bölgesi sayesinde, işlem sonrasında dış çerçevedeki bozulan kısımlar kırılarak kaldırılır. Daha sonra, düzeltilmiş küçük parçalar birleştirilerek büyük bir harita elde edilir. Bu yöntem, derin sinir ağı tarafından işlenen görüntülerde ortaya çıkan bozulmaları minimize etmek ve nihai haritanın kalitesini artırmak amacıyla kullanılmıştır.

Her bir 544x544 boyutunda görüntü parçası, bicubic yeniden örnekleme metodu ile 50% oranında (272x272) yeniden örneklendirilmiştir. Daha sonra, bicubic yeniden örnekleme metodu tekrar kullanılarak görüntü 200% oranında büyütülmüştür. Elde edilen düşük öz nitelikli aynı boyutlu görüntü, asıl görüntünün soluna yerleştirilerek, 1088x544 boyutunda görüntüler elde edilmiştir, bu Şekil 3'te gösterilmektedir.



Şekil 3. a) Düşük uzamsal çözünürlüklü görüntü, b) yüksek uzamsal çözünürlüklü görüntü

Bu yöntem kullanılarak, 11742 adet eğitim verisi oluşturuldu ve bu veriler arasından 10942 adet görüntü, sinir ağının eğitiminde kullanılmak üzere uygun görüldü. Eğitilen modelin doğruluğunu test etmek için ise 800 adet eğitim verisi seçildi.

Testler, PSNR (Peak Signal-to-Noise Ratio), SSIM (Structural Similarity Index Measure), ve MSE (Mean Squared Error) metrikleri kullanılarak gerçekleştirilmiştir. PSNR, yeniden oluşturulan bir görüntünün kalitesinin değerlendirilmesinde yaygın olarak kullanılan bir metriktir. Bu metrik, sinyalin maksimum olası değeri ile oluşan görüntü arasındaki ilişkiyi tanımlamak için kullanılmaktadır. MSE (Mean Squared Error) ise, orijinal görüntü (Y) ile yeniden oluşturulmuş görüntü (Y') arasındaki ortalama karesel hata değerini gösterir. Metriklerin denklemleri aşağıda verilmiştir.

$$PSNR(Y, Y') = 20 * \log_{10} \left( \frac{MAX_Y}{MSE(Y, Y')} \right) \quad (1)$$

$$MSE(Y, Y') = \frac{1}{HWC} \sum_{h=1}^H \sum_{w=1}^W \sum_{c=1}^C (Y_{h,w,c} - Y'_{h,w,c})^2 \quad (2)$$

Burada H, W, C sırasıyla görüntünün yüksekliğini, genişliğini ve kanal sayısını ifade etmektedir.

Yapısal Benzerlik (SSIM) metriği, iki görüntü arasındaki benzerliği parlaklık, kontrast ve yapı gibi faktörler dikkate alarak ölçer. Bu metrik, insanların görsel benzerlikleri algılamasına daha yakın bir yaklaşım sunmaktadır. Metrik değerleri aralığı [-1,1] olup, 1 değeri iki görüntünün aynı olduğunu gösterir. Orijinal görüntü  $Y$  ve yeniden oluşturulmuş görüntü  $\hat{Y}$  arasındaki yapısal benzerlik ise, aşağıdaki denklem ile tanımlanır. Metriğin denklemi aşağıda verilmiştir.

$$SSIM(Y, \hat{Y}) = \frac{(2\mu_y\mu_{\hat{y}} + C_1)(\sigma_y\sigma_{\hat{y}} + C_2)}{(\mu_y^2\mu_{\hat{y}}^2 + C_1)(\sigma_y^2\sigma_{\hat{y}}^2 + C_2)} \quad (3)$$

Denklemden  $\mu_y$  ve  $\mu_{\hat{y}}$   $Y$ ,  $\hat{Y}$  'nin ortalamasını,  $\sigma_y$  ve  $\sigma_{\hat{y}}$   $Y$ ,  $\hat{Y}$  'nin varyansını,  $\sigma_y^2$  ve  $\sigma_{\hat{y}}^2$  ise  $Y$  ve  $\hat{Y}$  'nin kovaryansını ifade etmektedir.  $C_1$  ve  $C_2$  ise denklemin daha stabil çalışmasını sağlayan sabitlerdir.

$C_1 = (K_1L)^2$  ve  $C_2 = (K_2L)^2$  şeklinde hesaplanır. Burada  $L$ , görüntülerin maksimum piksel değerini ifade etmektedir ve  $K_1$  ve  $K_2$  sırasıyla 0,01 ve 0,03 olarak ayarlanmıştır.

## 2.5. Eğitim süreci

Modelimiz, Adam optimizasyon yöntemi kullanılarak  $\beta_1=0,9$  ve  $\beta_2=0,999$  parametreleriyle eğitilmektedir. Başlangıç öğrenme oranı olarak  $3 \cdot 10^{-4}$  kullanılmıştır ve her 100 döngü(epoch) sonrası öğrenme oranı yarıya düşürülmektedir. Eğitimde kullanılan yığın (batch) büyüklüğü 8 olarak ayarlanmıştır. Son olarak, temel sinir ağı modelimiz 200% süper çözünürlük durumu için toplam 194433 adet eğitilebilir parametreye sahiptir.

Oluşturduğumuz otokodlayıcı sinir ağı modeli, TensorFlow/Keras kütüphanesi ve NVIDIA RTX 3060 grafik kartı kullanılarak Python programlama dili ile eğitilmiştir. Eğitim sonuçları, MSE, PSNR ve SSIM metrikleri kullanılarak değerlendirilmiştir. Test sonuçları, diğer yöntemler (bicubic, srcnn) ile karşılaştırmalı şekilde sunulmuştur ve bu karşılaştırma tablo 3'te verilmiştir.

## 3. Bulgular ve Tartışma

Tablo 3'te uydu görüntü parçalarının farklı interpolasyon yöntemleri için PSNR, MSE ve SSIM metrikleri dahilinde sonuçlar görülmektedir.

Yapılan çalışmada, En Yakın Komşu, Bicubic metodu ile SRCNN ve SEN-2\_CAENET (Sentinel-2 Convolutional Auto Encoder Net) sinir ağları kullanılarak görüntü iyileştirme performansları değerlendirilmiştir. Görüntülerin özneliklerini, iç yapısını, dönüşümlerini ve stil bilgisini öğrenmek için kullanılan bir sinir ağı türü olan otokodlayıcılar, süper çözünürlük yöntemi olarak kullanıldığında SRCNN gibi sinir ağlarına karşı bazı avantajları vardır. Otokodlayıcı sinir ağları, görüntülerin düşük boyutlu bir gizli uzaya sıkıştırılmasını ve daha sonra yüksek uzamsal çözünürlüklü bir görüntüye yeniden oluşturulmasını kullanarak, görüntülerin özneliklerini, iç yapısını, dönüşümlerini ve stil bilgisini yakalar (Zeng vd. 2015). Bu, süper çözünürlük yöntemi için etkili bir yaklaşımdır, çünkü görüntülerin düşük uzamsal çözünürlüklü versiyonlarından daha yüksek uzamsal çözünürlüklü görüntüler oluşturmayı sağlar.

SRCNN modeline karşı üstünlük olarak, etiketli veri gerektirmeyen veya çok az gerektiren denetimsiz veya yarı denetimli bir şekilde eğitilebilirler, bu da gerçek dünya verileriyle daha uyumlu ve esnektir. Ayrıca, bu yöntem, farklı kaynaklardan gelen görüntüler arasındaki bozulma faktörlerini aktarmak veya azaltmak için görüntülerin stil bilgisini de kullanabilir (Chen ve Guo, 2023).


Çalışmadaki bulgular da göstermiştir ki, en iyi performansı sağlayan metod evrişimli otokodlayıcı süper çözünürlük yaklaşımı olan SEN-2\_CAENET metodudur. Bu metod, diğer metotlara göre daha düşük MSE değerine ve daha yüksek PSNR ve SSIM değerine sahiptir ve SRCNN ağına kıyasla çözünürlük yükseltme amaçlı daha az parametre ihtiyacı duyduğunu, daha kısa sürede eğitildiğini ve daha düşük hesaplama maliyeti gerektirdiğini göstermektedir.

Tablo 3. Test sonuçları

		PSNR	MSE	SSIM
Görüntü 1	En yakın Komşu (NN)	28.13958937	299.3937142	0.832194964
	Bicubic	31.92172766	125.3224421	0.902395991
	SRCNN	34.13792911	75.23305618	0.942640911
	<b>SEN-2_CAENET</b>	<b>34.42641473</b>	<b>70.39797108</b>	<b>0.947942333</b>
Görüntü 2	En yakın Komşu	28.61196781	268.5374338	0.848078873
	Bicubic	32.89465271	100.1696935	0.917132618
	SRCNN	36.02491789	48.72028568	0.951238737
	<b>SEN-2_CAENET</b>	<b>36.57139958</b>	<b>42.95974132</b>	<b>0.956290192</b>
Görüntü 3	En yakın Komşu	26.95224926	393.5289521	0.771734962
	Bicubic	30.62953086	168.751845	0.862701864
	SRCNN	32.88058618	100.494663	0.91663712
	<b>SEN-2_CAENET</b>	<b>33.02969116</b>	<b>97.10296699</b>	<b>0.920177722</b>
Görüntü 4	En yakın Komşu	27.45648718	350.390964	0.820088027
	Bicubic	31.38165974	141.9173985	0.893843209
	SRCNN	33.71147899	82.99534165	0.936201593
	<b>SEN-2_CAENET</b>	<b>34.00720942</b>	<b>77.531944</b>	<b>0.941528229</b>
Görüntü 5	En yakın Komşu	30.49324886	174.1312547	0.878267689
	Bicubic	34.48008223	69.5333883	0.928980097
	SRCNN	37.80508327	32.33652063	0.958132996
	<b>SEN-2_CAENET</b>	<b>38.57819468</b>	<b>27.06338699</b>	<b>0.963250572</b>

En Yakın Komşu, Bicubic metodu ile SRCNN ve SEN-2\_CAENET (Sentinel-2 Convolutional Auto Encoder Net) sınır ağları'nın görsel sonuçları Şekil 4'te verilmiştir.





**Şekil 4.** a) orijinal görüntüyü, b) En Yakın Komşu algoritmasını, c) bicubic yöntemini, d) SRCNN sinir ağı yöntemini, e) SEN-2\_CAENET sinir ağı yaklaşımını ifade etmektedir

Sentinel-2 uyduları veri seti, coğrafi bilgi sistemleri, hava durumu tahminleri ve diğer uygulamalarda yaygın olarak kullanılan uydu görüntüleri için idealdir. Ancak, uydu görüntülerinin sınırlı çözünürlüğü, bilgi toplama ve anlamlandırma sürecinde birtakım zorluklar oluşturabilir. Bu makalede, Sentinel-2 uyduları veri setinin süper çözünürlük amaçlı evrişimli otokodlayıcı sinir ağı için eğitim verisi olarak kullanılmasının başarılı sonuçlar verdiği görülmüştür.

## 4. Sonuçlar

Yapılan çalışmalar sonucunda, SEN-2\_CAENET metodunun diğer metotlara göre daha yüksek bir performansa sahip olduğu ortaya konmuştur. Bu sonuç, PSNR, MSE ve SSIM gibi performans metriklerinin kullanımıyla desteklenmiştir. SEN-2\_CAENET metodu en yüksek PSNR değerine, en düşük MSE değerine ve en yüksek SSIM değerine sahip olarak görüntü iyileştirme performansını en iyi şekilde sağlamıştır.

Bu bulgular, görüntü iyileştirme alanındaki var olan bilgi ve literatür ile karşılaştırıldığında, SEN-2\_CAENET metodunun performansının SRCNN'den daha iyi performans sağladığını göstermektedir. Ayrıca, bu metodun gelecekte daha fazla veri ve metot kullanarak daha da geliştirilebileceği ve benzer çalışmalarda referans alınabileceği önerilmektedir.

Bu çalışmanın sonuçları, görüntü iyileştirme alanındaki diğer uygulamalar için de faydalı olabileceği öngörülmektedir. Örneğin, bu evrişimli otokodlayıcı süper çözünürlük yaklaşımı, görüntü sıkıştırması, görüntü analizi ve görüntü işleme gibi uygulamalarda da kullanılabilir. Bununla birlikte, daha detaylı ve geniş çalışmalara ihtiyaç duyulabilir, ancak bu çalışma, görüntü iyileştirme alanında fikir verebilmek için yeterli bir temel sunmaktadır.

## Kaynaklar

- Cengiz, A., & Avcı, D. (2021). Uydu imgelerine derin öğrenme tabanlı süper çözünürlük yöntemlerinin uygulanması. *Afyon Kocatepe University Journal of Sciences and Engineering*, 21(5), 1069-1077.
- Chen, S., & Guo, W. (2023). Auto-encoders in deep learning—a review with new perspectives. *Mathematics*, 11(8), 1777. doi: 10.3390/math11081777.
- 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.
- Dong, C., Loy, C. C., & Tang, X. (2016). Accelerating the Super-Resolution Convolutional Neural Network. In B. Leibe, J. Matas, N. Sebe, M. Welling (Eds.), *Computer Vision – ECCV 2016* (pp. 391-407). Springer.
- Dong, R., Mou, L., Zhang, L., Fu, H., & Zhu, X. X. (2022). Real-world remote sensing image super-resolution via a practical degradation model and a kernel-aware network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 191, 155-170.
- ESA. (2023a, Eylül). *MultiSpectral Instrument (MSI) Overview*. Retrieved from <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>.
- ESA. (2023b, Eylül). *Science Toolbox Exploitation Platform*. Retrieved from <https://step.esa.int/main/download/snap-download/>.
- Galar, M., Sesma, R., Ayala, C., Albizua, L., & Aranda, C. (2020). Super-resolution of Sentinel-2 images using convolutional neural networks and real ground truth data. *Remote Sensing*, 12(18), 2941. doi: 10.3390/RS12182941.
- Lanaras, C., Bioucas-Dias, J., Galliani, S., Baltsavias, E., & Schindler, K. (2018). Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 305-319.
- Leite, N. M. N., Pereira, E. T., Gurjão, E. C., & Veloso, L. R. (2018, December). Deep convolutional autoencoder for EEG noise filtering. In *IEEE International Conference on Bioinformatics and Biomedicine, 2018. Proceedings*. (pp.2605-2612). IEEE.
- Liu, H., Fu, Z., Han, J., Shao, L., & Liu, H. (2018). Single satellite imagery simultaneous super-resolution and colorization using multi-task deep neural networks. *Journal of Visual Communication and Image Representation*, 53, 20-30.
- Liu, L., Jiang, Q., Jin, X., Feng, J., Wang, R., Liao, H., Lee, S. J., & Yao, S. (2022). CASR-Net: A color-aware super-resolution network for panchromatic image. *Engineering Applications of Artificial Intelligence*, 114, 105084. doi: 10.1016/j.engappai.2022.105084.
- Liu, Z., Lian, T., Farrell, J., & Wandell, B. A. (2020). Neural network generalization: The impact of camera parameters. *IEEE Access*, 8, 10443-10454.
- Pineda, F., Ayma, V., & Beltran, C. (2020). A generative adversarial network approach for super-resolution of sentinel-2 satellite images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 43(B1), 9-14. doi:10.5194/isprs-archives-XLIII-B1-2020-9-2020.
- Salgueiro Romero, L., Marcello, J., & Vilaplana, V. (2020). Super-resolution of sentinel-2 imagery using generative adversarial networks. *Remote Sensing*, 12(15), 2424. doi: 10.3390/RS12152424.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015, June). Going deeper with convolutions. In *Conference On Computer Vision And Pattern Recognition, 2015. Proceedings*. (pp. 1-9). IEEE.
- Turhan, C. G., & Bilge, H. Ş. (2019). Çekişmeli üretici ağ ile ölçeklenebilir görüntü oluşturma ve süper çözünürlük. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(2), 953-966.

- Wang, P., Bayram, B., & Sertel, E. (2022). A comprehensive review on deep learning based remote sensing image super-resolution methods. *Earth-Science Reviews*, 232, 104110. doi: 10.1016/j.earscirev.2022.104110.
- Yang, W., Zhang, X., Tian, Y., Wang, W., Xue, J. H., & Liao, Q. (2019). Deep learning for single image super-resolution: A brief review. *IEEE Transactions on Multimedia*, 21(12), 3106-3121.
- Zabalza, M., & Bernardini, A. (2022). Super-resolution of sentinel-2 images using a spectral attention mechanism. *Remote Sensing*, 14(12), 2890. doi: 10.3390/rs14122890.
- Zeng, K., Yu, J., Wang, R., Li, C., & Tao, D. (2015). Coupled deep autoencoder for single image super-resolution. *IEEE Transactions on Cybernetics*, 46(10), 27-37.