

## Otokodlayıcılar Kullanarak Uzaktan Algılama Görüntülerindeki Eksik Verilerin Yeniden Yapılandırılması

Serkan KARTAL\*<sup>1</sup> ORCID 0000-0001-9801-8986

<sup>1</sup>Çukurova Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Adana

Geliş tarihi: 25.05.2022

Kabul tarihi: 27.12.2022

Atıf şekli/ How to cite: KARTAL, S., (2022). Otokodlayıcılar Kullanarak Uzaktan Algılama Görüntülerindeki Eksik Verilerin Yeniden Yapılandırılması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 37(4), 853-862.

### Öz

Uzaktan algılama çalışmalarında uydu görüntülerindeki eksik verilerin yeniden yapılandırılması, veri kullanılabilirliğini artırmak ve analiz süreçlerini kolaylaştırmak açısından büyük önem taşımaktadır. Bu çalışmada, bu problemi çözmek için otokodlayıcı adı verilen Yapay Sinir Ağı (YSA) modeli kullanılmıştır. Çalışmanın amacı, büyük oranda eksik veri içeren ve bu nedenle interpolasyon gibi klasik yöntemlerle yüksek doğrulukla yeniden yapılandırılması zor olan uydu görüntülerini başarılı bir şekilde yeniden yapılandırılacak bir YSA modelinin geliştirilmesidir. Model, Orta Çözünürlüklü Görüntüleme Spektrometresi (MODIS) sensörleri ile elde edilen 1-km çözünürlüğe sahip günlük (MYD11A1) yüzey sıcaklığı verileri üzerinde test edilmiştir. Çalışma alanı Türkiye'nin güneyinde yer alan, Antalya ilinin kuzeyi ile Burdur ve Isparta il sınırları içerisinde bulunan bir bölgeyi kapsamaktadır. 2017-2020 tarih aralığına ait 306 veri üzerinde yapılan çalışma sonucunda modelin %70 ve üzerinde eksik bilgi içeren verileri 1,79 Ortalama Mutlak Hata (OMH) değeri ile tamamlayabildiği görülmüştür.

**Anahtar Kelimeler:** Yapay sinir ağları, Otokodlayıcılar, Uzaktan algılama, MODIS, Yeniden yapılandırma

### Reconstruction of Missing Data in Remote Sensing Images Using Autoencoders

#### Abstract

Reconstruction of missing data in satellite images in remote sensing studies is of great importance in terms of increasing data availability and facilitating analysis processes. In this study, an Artificial Neural Network (ANN) model called an autoencoder was used to solve this problem. The study aims to develop an ANN model that will successfully reconstruct satellite images that contain largely missing data and are therefore difficult to reconstruct with high accuracy by classical methods such as interpolation. The model was tested on daily surface temperature data (MYD11A1) with 1-km resolution obtained with Moderate Resolution Imaging Spectroradiometry (MODIS) sensors. The study area covers a region located in the south of Turkey, in the north of Antalya province, and within the borders of Burdur and Isparta. As a result of the study carried out on 306 images belonging to the 2017-2020 date range, it was seen that the model was able to reconstruct the images containing 70% or more missing data with a Mean Absolute Error (MAE) value of 1.79.

**Keywords:** Neural networks, Autoencoders, Remote sensing, MODIS, Reconstruction

\* Sorumlu yazar (Corresponding Author): Serkan KARTAL, skartal@cu.edu.tr

## 1. GİRİŞ

Uzaktan algılama verileri arazi yüzey analizinden iklim değişikliği tespitine, ekosistem analizinden doğal afet durumu tespitine kadar birçok farklı alanda başarıyla kullanılmaktadır [1-10]. Ancak, pasif algılayıcılara sahip uydu sistemlerinin çalışma koşulları ve atmosferik koşullar nedeniyle, uzaktan algılama verileri genellikle eksik bilgiler içerirler [11]. Bu durum başta zaman serisi verileri kullanılarak yapılan çalışmalar olmak üzere birçok uzaktan algılama çalışmasının yapılmasını zorlaştırmakta ya da engellemektedir [12]. Bu nedenle uydu verileri içerisindeki eksik bilgilerin (veri olmayan piksellerin) tamamlanması, uzaktan algılama verilerinin kullanılabilirliğini artırarak bu alanda yapılan çoklu zaman analizi çalışmalarına önemli katkılar sağlayacaktır.

Literatürde, uzaktan algılama görüntülerinde eksik bilgilerin yeniden yapılandırılması için yapılmış çalışmalar göz önünde bulundurulduğunda, geliştirilen yöntemler dört ana başlık altında sınıflandırılabilir: 1- mekan tabanlı yöntemler; 2- spektral tabanlı yöntemler; 3- zaman tabanlı yöntemler; 4- bu yöntemlerin birkaçını aynı anda içerisinde barındıran hibrit yöntemler. Mekan tabanlı yöntemler, veri içerisindeki eksik bilgileri yine aynı veri içerisindeki diğer bilgileri kullanarak tamamlarlar. Bu yöntemler, aynı veri içerisinde bilgi içeren bölgelerin, eksik bilgi içeren bölgelerle aynı istatistiksel ve dokusal özellikler taşıdığı fikrine dayanır. İnterpolasyon yöntemleri ve  $k$  en yakın komşu (knn) yöntemleri bu alandaki çalışmalarda en sık kullanılan yöntemlerdir [13-15]. Mekan tabanlı bir çalışmada veri içerisindeki eksik bilgileri doldurmak için eksik bilgi etrafındaki bilgilerin ağırlıklı ortalamasının kullanılması bu çalışmalara bir örnek olarak verilebilir. Bu yöntemlerin en önemli avantajları basit olmaları ve içerisinde az miktarda eksik bilgi içeren veriler için başarılı sayılabilecek sonuçlar vermeleridir. Ancak bu algoritmalar, içerisinde büyük bilgi eksikliği olan ve karmaşık bir örüntüye sahip olan uzaktan algılama verileri için yeterli değildir.

Alternatif olarak kullanılan bir diğer yeniden yapılandırma yöntemi ise spektral tabanlı

yaklaşımlardır. Bu yöntemler, genellikle farklı spektral veriler arasında yüksek bir korelasyon olduğu fikrine dayanır. Buna göre bulut örtüsü nedeniyle elde edilemeyen bölgelere ait eksik bilgiler, bulutlara duyarlı olmayan spektral bantlardan elde edilen bilgilere dayanarak tamamlanmaktadır. Örnek olarak Moderate Resolution Imaging Spectroradiometer (MODIS) verileri içerisindeki 6. ve 7. bantlar arasındaki korelasyon göz önünde bulundurularak, 6. banda ait eksik bilgilerin doldurulması için 7. banda ait bilgilerin kullanıldığı birçok çalışma bulunmaktadır [16-18]. Yüksek korelasyona sahip diğer bant bilgileri, eksik bilgilerin tamamlanmasında yüksek tutarlılıkta sonuçlar üretmekle birlikte, bu yaklaşımlarda yine farklı bant bilgilerine bağımlılık oluşturmakta ve kalın bulut örüntülerinin olduğu bölgelerde sorunlar yaşanabilmektedir.

Veriler arasındaki zamansal bağlamdaki korelasyonların kullanıldığı diğer yöntemler ise, uyduların aynı bölge için sabit aralıklarla veri alması koşuluna dayanmaktadır. Bir çalışmada Tseng ve arkadaşları [19], bulut sebebiyle eksik bilgiye sahip olan bölgeleri, zamansal düzlemde aynı konuma sahip en yakın komşu verileri ile doldürmüşlerdir. Benzer bir diğer çalışmada ise Yin ve arkadaşları [20], veri içerisinde eksik bilgilerin olduğu bölgeleri, çok zamanlı uydu görüntüsünün zamansal korelasyonuna dayanarak, ilgili bölgelerin tam olduğu diğer veriler içerisinde kopyalayarak doldürmüştür. Bunlara ilave olarak, literatürde bu üç yöntemin birkaçını aynı anda kullanarak geliştirilmiş birçok hibrit çalışma da bulunmaktadır [21].

Diğer taraftan, son zamanlarda diğer bir çok alanda olduğu gibi, uzaktan algılama alanında da makine öğrenmesi algoritmalarının kullanımı yaygınlaşmaya başlamıştır. Zhang ve arkadaşları [22] evrişimli sinir ağı tabanlı, birden fazla banttaki verilerden faydalanarak hem zamansal hem de mekansal örüntüler yardımıyla eksik bilgileri dolduran bir algoritma önermişlerdir. Yapılan bir başka çalışmada Das ve Ghosh [23], uzaktan algılamada zaman serisi verilerindeki eksik verileri yeniden yapılandırmak için Deep-STEP\_FE adında derin öğrenme tabanlı bir

yöntem önermişlerdir. Shao ve arkadaşları [24] yaptıkları bir çalışmada eksik bilgilerin tamamlanması için evrişim ve dikkat mekanizmalarının bulunduğu iki aşamalı bir yöntem önerirken, daha sonra yaptıkları diğer bir çalışmada [25] üretken çekişmeli ağ tabanlı yeni bir yöntem önermişlerdir.


Bu çalışmada ise, uzaktan algılama görüntülerindeki eksik verileri yeniden yapılandırmak için, son zamanlarda özellik çıkarımı, gürültü temizleme, aykırı durum tespiti ve eksik veri doldurma gibi birçok farklı alanda yaygın olarak kullanılan otokodlayıcı Yapay Sinir Ağı (YSA) modeli kullanılmıştır [26-32]. Çalışmada veri seti olarak 2017-2020 yılları arasındaki MODIS arazi yüzey sıcaklığı (MYD11A1) verileri ele alınmıştır. Çalışmanın temel amacı, yüksek oranda eksik bilgi içermesi nedeniyle klasik algoritmalarla tamamlanması zor olan verileri yüksek başarı oranı ile tamamlayabilecek bir YSA modelinin

geliştirilmesidir. Bu amaçla geliştirilen modelin performansı her biri en az %70 eksik veriye sahip test verileri üzerinde değerlendirilmiştir.

## 2. MATERYAL VE METOT

### 2.1. Çalışma Alanı

Çalışma alanı Türkiye'nin güneyinde, Antalya ilinin kuzey kesimleri ile Burdur ve Isparta sınırları içerisinde bir bölgeyi kapsamaktadır. Kullanılan bilgisayarın donanım kısıtları göz önünde bulundurularak, çalışma 128X128 piksellik bir alan üzerinde gerçekleştirilmiştir. Çalışma için bu bölgenin seçilmesinin en önemli nedeni, bölgedeki yüzey sıcaklığı değerlerinin tek düze olmaması, bölgede hem yüksek hem de düşük sıcaklık değerlerinin ölçülmesi, yani bölgenin kendi içerisinde bir yüzey sıcaklığı örüntüsüne sahip olmasıdır.



**Şekil 1.** Örnek bir MODIS verisi üzerinde çalışma alanının genel bir görüntüsü. Şekilde kare içerisinde kalan bölge, 128x128 piksel boyutundaki çalışma alanını göstermektedir


Bu da, interpolasyon gibi klasik algoritmalar yerine, bölgedeki yüzey sıcaklık örüntüsünü öğrenerek eksik veri değerlerini bu örüntü yardımıyla doldurabilecek YSA tabanlı algoritmaların kullanımını gerektirmektedir. Çalışma alanının Türkiye içerisindeki konumu Şekil 1 üzerinde kare içerisine alınarak gösterilmiştir.

Çalışmada 1-km'lik çözünürlüğe sahip günlük MYD11A1 verileri kullanılmıştır. Eğitim veri seti oluşturulurken 2017-2020 yılları arasından %5'ten daha az eksik veriye sahip MYD11A1 görüntüleri ele alınmış ve bu görüntüler içerisindeki eksik kısımlar klasik interpolasyon yöntemi ile tamamlanmıştır. İnterpolasyon yöntemi, veri içerisinde çok az miktarda eksik bilgi olduğunda, yani boş veriye yakın ve interpolasyon için kullanılabilir çok sayıda gerçek veri bulunduğu yüksek başarı oranı ile çalışmaktadır. Bu işlemler sonucunda 306 adet veriden oluşan bir veri seti oluşturulmuştur. Bu verilerin %80'i (246) eğitim, %10'u (30) geçerlilik, geriye kalan %10'luk (30) kısmı ise test amaçlı kullanılmıştır.

## 2.2. Otokodlayıcılar


Otokodlayıcılar, ya da diğer bir ismiyle otomatik kodlayıcılar, denetimsiz öğrenmenin gerçekleştiği bir yapay sinir ağı modelidir. Otokodlayıcı modelleri giriş verilerini çıkışa kopyalamaya çalıştıklarından harici olarak etiketlenmiş bir veri setine ihtiyaç duymazlar. Bu nedenle öz-denetimli öğrenme modeli olarak da adlandırılırlar. Model, kodlayıcı (encoder) ve kod çözücü (decoder) adı verilen iki temel bileşenden oluşmaktadır. Modelin genel mimarisi Şekil 2'de verilmiştir.

Kodlayıcı modülü, girdi verisi içerisindeki anlamlı bilgileri öğrenmek için, giriş katmanından gelen verileri bir darboğaza sokar. Bu darboğaz sayesinde kodlayıcı kısım verideki önemli olan özellikleri öğrenmeye mecbur kalır. Daha sonra kodlayıcı kısımda hesaplanan veriler, modelin kod-çözücü bileşenine doğru iletilir. Kod-çözücü ise kodlayıcı tarafından kodlanan bilgileri çözerek, ilk girdi verisini yeniden oluşturmaya çalışır. Girdi verisi ile çıktı verisinin aynı olması amaçlandığından bu işleme yeniden yapılandırma (reconstruction) adı verilir. Girdi ile çıktı arasındaki fark ise modelin hatasını oluşturur ve hatanın geriye yayılarak ağırlıkların güncellenmesi ile modelin öğrenmesi gerçekleşir.



Şekil 2. Otokodlayıcı modelinin genel mimarisi.  $x_n$   $n$  inci giriş değerini gösterirken  $\hat{x}_n$   $n$  inci çıkış değerini göstermektedir

**Çizelge 1.** Eğitim sürecinde modelin 0, 25, 50 ve 100. iterasyonlarda aynı test verisi üzerinde yapılan tahmin işlemlerinin sonuçları



Bu süreç, modelin dayandığı temel çalışma prensibini ortaya koymakla birlikte kullanılacak modelin kullanım şekli; gürültü temizleme, eksik verilerin tamamlanması, özellik çıkarımı gibi farklı problemler için ufak farklılıklar gösterebilmektedir.

Bu çalışmada 4 katmanlı bir kodlayıcı ile 4 katmanlı bir kod-çözücü içeren otokodlayıcı

modeli tasarlanmıştır. Modelin eğitimi için Adam (Adaptive Moment Estimation) olarak adlandırılan “Uyarlanabilir Moment Tahmini” optimizasyon algoritması kullanılmıştır. Modelin hatasını hesaplamak için ise karesel hata fonksiyonu kullanılmıştır. Model Python programlama dili ve Keras kütüphanesi kullanılarak kodlanmıştır. Amaç eksik bilgiler içeren MYD11A1 verilerini tamamlayacak bir model geliştirmek olduğundan,

model, içerisindeki bilgilerin %70'i rastgele silinmiş veriler ile beslenmiş, modelin ürettiği sonuçlar ise verilerin gerçek (tam) halleri ile karşılaştırılmıştır. Elde edilen hata değerleri geriye yayılarak modelin eksik verilerden tam bir MYD11A1 verisi oluşturmayı öğrenmesi sağlanmıştır. Model 100 iterasyon boyunca eğitilmiş olup, 0, 25, 50 ve 100. iterasyonlarda örnek bir veri üzerindeki tahmin sonuçları Çizelge 1'de gösterilmiştir. Çizelgedeki sonuçlar modelin iterasyonlar boyunca nasıl öğrendiğini ve %70'i eksik olan bir veriyi nasıl tamamlama yeteneği kazandığını adım adım göstermektedir. Çizelgedeki verilere göre modelin 25. iterasyonda bölgenin yüzey sıcaklığı örüntüsünü kabaca öğrendiği, 50. iterasyonda örüntüyü büyük oranda öğrendiği, devam eden eğitim sürecinde ise örüntü üzerinde küçük değişikliklerin olduğu görülmektedir.

### 2.3. Hata Ölçüm Metrikleri

Bu çalışmada geliştirilen modelin hatasını ölçmek için, literatürde yaygın olarak Karesel Ortalama Hata (KOH) ve Ortalama Mutlak Hata (OMH) metrikleri kullanılmıştır. Her iki metriğin denklemleri aşağıda verilmiştir.

$$KOH = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (1)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (2)$$

burada  $x_i$  ve  $\hat{x}_i$ , sırasıyla  $i$ . gerçek değeri ve  $i$ . tahmin edilen değeri temsil etmektedir.  $n$  ise veri setindeki toplam veri sayısını tutmaktadır. Tahmin işlemi sırasında düşük hata değeri elde etmek yüksek başarı göstergesidir.

## 3. BULGULAR VE TARTIŞMA

Bu çalışmada 2017-2020 yılları arasında Antalya'nın kuzeyi ile Burdur ve Isparta illerinin bulunduğu bölgeye ait MYD11A1 verileri içerisindeki eksik bilgilerin otokodlayıcılar ile

tamamlanması incelenmiştir. Toplamda 306 adet veriden oluşan bir veri seti kullanılmıştır. Veri setinin %80'i eğitim ve %10'u doğrulama için kullanılırken, modelin başarısını değerlendirmek için eğitim süresince hiç kullanılmayan ve toplam veri setinin %10 una karşılık gelen 30 adet test verisi kullanılmıştır. Test verileri için elde edilen hata değerleri Çizelge 2'de verilmiştir.

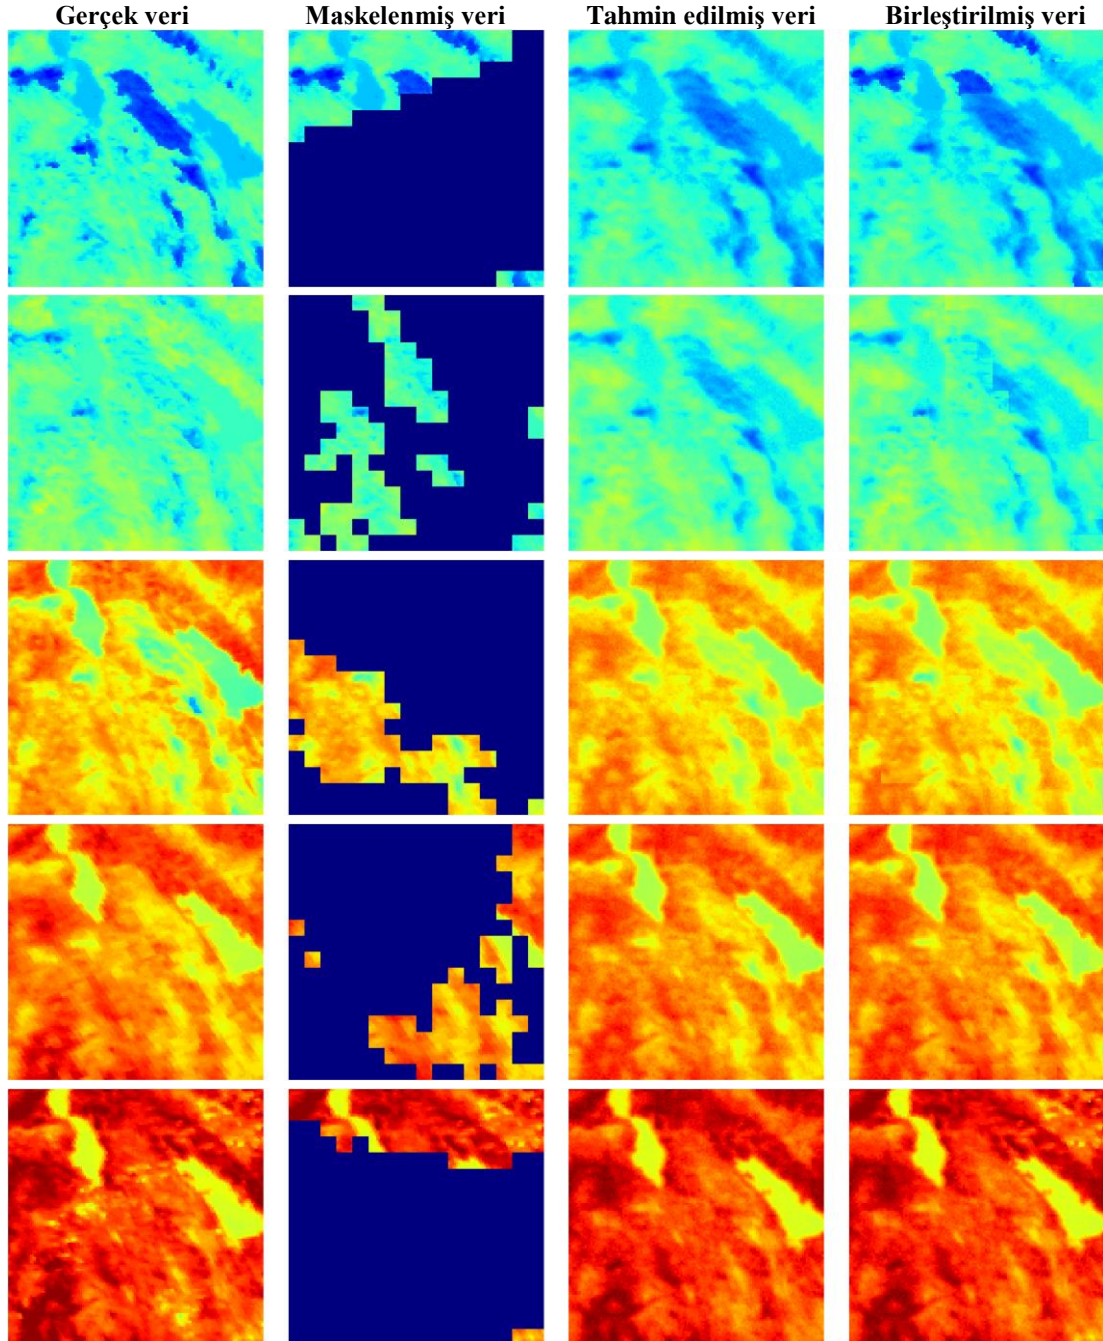
**Çizelge 2.** Otokodlayıcı modeline ait KOH ve OMH değerleri

KOH	2,28
OMH	1,79

Geliştirilen otokodlayıcının performansı değerlendirilirken, tahmin edilen eksik bilgiler ile bu bilgilerin gerçek değerleri arasındaki farklar göz önünde bulundurulmuştur. Bu çalışmada yapılan tahmin işlemi, belirli bir bölgeye ait tek bir değer tahmini olmadığından ve bölgenin tüm sıcaklık haritası içerisindeki eksik bilgiler doldurulmaya çalışıldığından, tahmin işlemin zorluk derecesi tek bir değer tahmini yapılan çalışmalara kıyasla daha zordur. Bunlara ilave olarak, çalışmanın amacı doğrultusunda tüm bir sıcaklık haritası değil, haritanın içerisindeki eksik bilgiler doldurulmaya çalışılmıştır. Dolayısıyla harita içerisindeki eksik bilgilerin sayısı da tahmin performansını etkileyen bir diğer etkidir. Eksik bilgi sayısının az olduğu verilerde, otokodlayıcı modeline daha fazla referans bilgi sağlanabileceğinden bu görüntüler için çok daha yüksek tutarlılıkta tahmin işlemlerin yapılabilmesi mümkündür. Ancak, eksik bilgi sayısının fazla olduğu verilerde ise otokodlayıcılara daha az referans bilgi sağlanabileceğinden hata miktarının da görece yüksek olması kaçınılmazdır.

Çalışmanın performansı değerlendirilirken, içerisinde en az %70 oranında eksik bilgiler bulunduran 30 adet MYD11A1 verisi seçilmiş ve bu verilerin içerisindeki eksik bilgiler maske olarak test verilerine uygulanmıştır. Maskeleme işleminden sonra test verileri içerisinde kalan bilgiler modele beslenerek verinin tam hali tahmin edilmeye çalışılmıştır.

**Çizelge 3.** Sırasıyla 5 adet gerçek test verisi, bu veriler üzerine gerçek bulut maskesi uygulanması sonucu elde edilen maskelenmiş veriler, otokodlayıcı model ile tahmin edilen veriler ve eldeki referans değerleri ile tahmin edilen değerlerin birleştirildiği nihai veriler



Böylece modelin performansı gerçek dünya senaryoları üzerinde test edilmiştir. Bu kapsamda 5 adet test verisinin gerçek görüntüleri, bu veriler üzerine gerçek bulut maskesi uygulanması sonucu elde edilen maskelenmiş veriler, otokodlayıcı model ile tahmin edilen veriler ve eldeki referans değerleri ile tahmin edilen değerlerin birleştirildiği veriler (nihai çıktı) Çizelge 3 içerisinde verilmiştir.

Test verileri içerisindeki eksik bilgi oranına ilaveten modelin performansını etkileyen bir diğer önemli etken ise, çalışılan bölgedeki yüzey sıcaklığı örüntüsüdür. Bölgesel sıcaklık değişiminin çok fazla gözlemlenmediği deniz yüzeyi gibi bir bölgedeki sıcaklık değerleri üzerinde tahmin yapmak çok daha kolayken, seçilen çalışma alanı gibi yüzey sıcaklığı değişiminin fazla olduğu bölgelerde bu tahmini yapmak daha zordur. Hatta sıcaklık farkının az olduğu bölgeler üzerinde sadece tüm değerlerin ortalamasını alarak bile düşük hata oranı ile tahmin işlemi gerçekleştirmek mümkün olabilmektedir. Ancak, bölgesel koşullara bağlı olarak sıcaklık değerlerin ilgili alan içerisinde farklılıklar gösterdiği bölgelerde, klasik yöntemlerin hesaplama prensiplerinden dolayı yüksek başarı elde edebilmeleri mümkün değildir. Bu noktada, bu bölgedeki sıcaklık örüntülerini yüksek tutarlılıkla öğrenerek sadece az bir referans değeri ile tahmin yapabilme yeteneğine sahip olan otokodlayıcılar gibi YSA tabanlı yöntemler ön plana çıkmaktadır. Bu bağlamda, Çizelge 3 içerisinde verilen örnek tahmin sonuçları ile geliştirilen otokodlayıcı modelinin ilgili bölgedeki yüzey sıcaklığı örüntüsünü öğrenebilme kapasitesini görsel olarak değerlendirmek mümkündür. Elde edilen sonuçlar otokodlayıcı modelinin bölge üzerindeki yüzey sıcaklığı örüntüsünü doğru bir şekilde öğrenerek, bu örüntüye uygun bir şekilde tahmin yaptığını açıkça göstermektedir.

#### 4. SONUÇLAR

Bu çalışmada, uzaktan algılama verilerindeki eksik bilgi probleminin çözülmesi için yapay sinir ağı tabanlı otokodlayıcı yöntemi kullanılmıştır. Çalışma, Türkiye'nin Güney kesiminde yer alan

Antalya ilinin kuzey kesimleri ile Burdur ve Isparta il sınırları içerisinde bulunan bir bölgeye ait veriler üzerinde gerçekleştirilmiştir. Veriler MODIS sensörleri ile elde edilmiş 2017-2020 tarih aralığına ait 306 adet günlük yüzey sıcaklığı verileridir. Çalışma sonuçları, geliştirilen otokodlayıcı modelin, %70'in üzerinde eksik bilgiye sahip olan verileri bile, mevcut yüzey sıcaklığı örüntülerini de koruyarak, sırasıyla KOH ve OMH metrikleri için 2.28'lik ve 1.79'lük hata miktarları ile tamamlanabildiğini göstermektedir. Çalışmanın, klasik interpolasyon yöntemleri ile tamamlanması çok zor olan yüksek miktarda eksik bilgiye sahip verilerdeki problemin giderilmesi için iyi bir alternatif oluşturduğu düşünülmektedir.

#### 5. KAYNAKLAR

1. Salmon, B.P., Olivier, J.C., Wessels, K.J., Kleynhans, W., Van Den Bergh, F., Steenkamp, K.C., 2010. Unsupervised Land Cover Change Detection: Meaningful Sequential Time Series Analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(2), 327-335.
2. Rahman, A., Aggarwal, S.P., Netzband, M., Fazal, S., 2010. Monitoring Urban Sprawl Using Remote Sensing and GIS Techniques of A Fast Growing Urban Centre, India. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(1), 56-64.
3. Ma, L., Li, M., Ma, X., Cheng, L., Du, P., Liu, Y., 2017. A Review of Supervised Object-Based Land-Cover Image Classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277-293.
4. Gómez, C., White, J. C., Wulder, M. A., 2016. Optical Remotely Sensed Time Series Data for Land Cover Classification: A Review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 55-72.
5. Li, F., Song, G., Liu, Z., Yanan, Z., Di, L., 2017. Urban Vegetation Phenology Analysis Using High Spatio-Temporal NDVI Time Series. *Urban Forestry & Urban Greening*, 25, 43-57.



6. Zhou, Y.N., Luo, J., Feng, L., Yang, Y., Chen, Y., Wu, W., 2019. Long-Short-Term-Memory-Based Crop Classification Using High-Resolution Optical Images and Multi-Temporal SAR Data. *GIScience & Remote Sensing*, 56(8), 1170-1191.
7. Kartal, S., Sekertekin, A., 2022. Prediction of MODIS Land Surface Temperature Using New Hybrid Models Based on Spatial Interpolation Techniques and Deep Learning Models. *Environmental Science and Pollution Research*, 1-20.
8. Zhang, Q., Ge, L., Zhang, R., Metternicht, G. I., Du, Z., Kuang, J., Xu, M., 2021. Deep-Learning-Based Burned Area Mapping Using the Synergy of Sentinel-1&2 Data. *Remote Sensing of Environment*, 264, 112575.
9. Belenguer-Plomer, M.A., Tanase, M.A., Chuvieco, E., Bovolo, F., 2021. CNN-Based Burned Area Mapping Using Radar and Optical Data. *Remote Sensing of Environment*, 260, 112468.
10. Shahabi, H., Shirzadi, A., Ghaderi, K., Omidvar, E., Al-Ansari, N., Clague, J.J., Geertsema, M., Khosravi, K., Amini, A., Bahrami, S., Rahmati, O., Habibi, K., Mohammadi, A., Nguyen, H., Melesse, A.M., Ahmad, B.B., Ahmad, A., 2020. Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: Hybrid Intelligence of Bagging Ensemble Based on K-Nearest Neighbor Classifier. *Remote Sensing*, 12(2), 266.
11. Shen, H., Li, X., Cheng, Q., Zeng, C., Yang, G., Li, H., Zhang, L., 2015. Missing Information Reconstruction of Remote Sensing Data: a Technical Review. *IEEE Geoscience and Remote Sensing Magazine*, 3(3), 61-85.
12. Wu, W., Ge, L., Luo, J., Huan, R., Yang, Y., 2018. A Spectral-Temporal Patch-Based Missing Area Reconstruction for Time-Series Images. *Remote Sensing*, 10(10), 1560.
13. Zhang, C., Li, W., Travis, D., 2007. Gaps-Fill of SLC-off Landsat ETM+ Satellite Image Using a Geostatistical Approach. *International Journal of Remote Sensing*, 28(22), 5103-5122.
14. Zhang, L., Wu, X., 2006. An Edge-Guided Image Interpolation Algorithm Via Directional Filtering and Data Fusion. *IEEE Transactions on Image Processing*, 15(8), 2226-2238.
15. Criminisi, A., Pérez, P., Toyama, K., 2004. Region Filling and Object Removal by Exemplar-Based Image Inpainting. *IEEE Transactions on Image Processing*, 13(9), 1200-1212.
16. Wang, L., Qu, J.J., Xiong, X., Hao, X., Xie, Y., Che, N., 2006. A New Method for Retrieving Band 6 of Aqua MODIS. *IEEE Geoscience and Remote Sensing Letters*, 3(2), 267-270.
17. Shen, H., Zeng, C., Zhang, L., 2010. Recovering Reflectance of AQUA MODIS Band 6 Based on Within-Class Local Fitting. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(1), 185-192.
18. Rakwatin, P., Takeuchi, W., Yasuoka, Y., 2008. Restoration of Aqua MODIS Band 6 Using Histogram Matching and Local Least Squares Fitting. *IEEE Transactions on Geoscience and Remote Sensing*, 47(2), 613-627.
19. Tseng, D. C., Tseng, H. T., Chien, C. L., 2008. Automatic Cloud Removal from Multi-Temporal SPOT Images. *Applied Mathematics and Computation*, 205(2), 584-600.
20. Lin, C.H., Tsai, P.H., Lai, K.H., Chen, J.Y., 2012. Cloud Removal from Multitemporal Satellite Images Using Information Cloning. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1), 232-241.
21. Gao, G., Gu, Y., 2017. Multitemporal Landsat Missing Data Recovery Based on Temporal Spectral Angle Model. *IEEE Transactions on Geoscience and Remote Sensing*, 55(7), 3656-3668.
22. Zhang, Q., Yuan, Q., Zeng, C., Li, X., Wei, Y., 2018. Missing Data Reconstruction in Remote Sensing Image with a Unified Spatial-Temporal-Spectral Deep Convolutional Neural Network. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4274-4288.
23. Das, M., Ghosh, S. K., 2017. A Deep-Learning-Based Forecasting Ensemble To Predict Missing Data for Remote Sensing Analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(12), 5228-5236.

24. Shao, M., Wang, C., Wu, T., Meng, D., Luo, J., 2020. Context-Based Multiscale Unified Network for Missing Data Reconstruction in Remote Sensing Images. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
25. Shao, M., Wang, C., Zuo, W., Meng, D., 2022. Efficient Pyramidal GAN for Versatile Missing Data Reconstruction in Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-14.
26. Zhang, C., Zhou, L., Zhao, Y., Zhu, S., Liu, F., He, Y., 2020. Noise Reduction in the Spectral Domain of Hyperspectral Images Using Denoising Autoencoder Methods. *Chemometrics and Intelligent Laboratory Systems*, 203, 104063.
27. Leite, N.M.N., Pereira, E.T., Gurjao, E.C., Veloso, L.R., 2018. Deep Convolutional Autoencoder for EEG Noise Filtering. In 2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), IEEE, 2605-2612.
28. Luo, X., Li, X., Wang, Z., Liang, J., 2019. Discriminant Autoencoder for Feature Extraction in Fault Diagnosis. *Chemometrics and Intelligent Laboratory Systems*, 192, 103814.
29. Li, Y., Huang, X., Li, J., Du, M., Zou, N., 2019. Specac: Spectral Autoencoder for Anomaly Detection in Attributed Networks. In Proceedings of the 28<sup>th</sup> ACM International Conference on Information and Knowledge Management, 2233-2236.
30. Tsai, D. M., Jen, P. H., 2021. Autoencoder-Based Anomaly Detection for Surface Defect Inspection. *Advanced Engineering Informatics*, 48, 101272.
31. Chen, Z., Yeo, C.K., Lee, B.S., Lau, C.T., 2018. Autoencoder-Based Network Anomaly Detection. In 2018 Wireless Telecommunications Symposium (WTS) (Pp. 1-5). IEEE.
32. Asadi, R., Regan, A., 2019. A Convolution Recurrent Autoencoder for Spatio-Temporal Missing Data Imputation. *Arxiv Preprint Arxiv:1904.12413*.