



TUFUAB -MERSİN 2021

<https://tufuab2021.mersin.edu.tr/>



Derin Öğrenme Yöntemleri ile Uydu Görüntülerinden Orman Yangını Tespiti: Muğla Örneđi

Onur Can Bayrak^{*1}, Tümay Arda¹, Melis Uzar¹

¹Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliđi Bölümü, İstanbul, Türkiye

Anahtar Kelimeler

Uzaktan Algılama,
Orman Yangını,
Derin Öğrenme,
Sınıflandırma

ÖZ

Ormanlar, oksijen dengesinin korunması, erozyonun önlenmesi, doğal hayata ev sahipliđi yapması, vb. sebeplerden dolayı korunması gereken doğal yaşam alanlarıdır. Yangınların önlenmesi ve takip edilmesi amacıyla ormanlık alanların izlenmesi gerekmektedir. Ormanlık alanların sahip olduđu geniş alanlar dikkate alındığında, izleme ve analiz işlemlerinin yapılması için en uygun veri kaynađı uydu görüntüleridir. Çalışma kapsamında; açık kaynaklı veri setinden eğitilen derin öğrenme modelleri ile 2021 yılı Ağustos ayında, Türkiye'nin Muğla ilinde meydana gelen aktif orman yangınlarına ait Landsat-8 uydu görüntüsü kullanılarak test edilmiş ve aktif olan yangınların olduđu alanlar tespit edilmiştir. Bu veri setinde eğitilen Inception-V3 ve Xception modelleri için sırasıyla %98.4 ve %99.5 doğruluk değeri elde edilmiştir. Xception modelinin daha başarılı performans göstermesi sebebiyle, bu model Muğla iline ait Landsat-8 görüntüsünde çalıştırılarak test görüntüsünde ise %97 oranında doğruluk değeri elde edilmiştir. Çalışmada, aktarımlı öğrenme tekniklerinin Landsat-8 görüntülerinde kullanılarak aktif orman yangınlarının bölgesel tespitinin yüksek doğruluk ile yapılabileceđi tespit edilmiştir.

Deep Learning-Based Active Fire Detection from Remote Sensing Imagery: A Case Study of Muğla

Keywords

Remote sensing,
Wildfire,
Deep Learning,
Classification

ABSTRACT

Forests, which are important for maintaining oxygen balance, preventing erosion and hosting natural life, are the areas need to be protected. To prevent wildfires, forests should be monitored regularly. Considering the large areas of forests, satellite images are the most suitable data source for monitoring and analysis. In the scope of this study; Deep learning models trained with open source data set have been tested by using Landsat-8 satellite image of active wildfire that occurred in Muğla province of Turkey in August 2021, and areas with active fires have been determined. For Inception-V3 and Xception models trained in this data set, 98.4% and 99.5% accuracy values were obtained, respectively. Due to the better performance of the Xception model, this model was run on the Landsat-8 image of Muğla province, and an accuracy value of 97% was obtained in the test image. In the study, it has been determined that the regional detection of wildfires can be made with high accuracy by using the transfer learning techniques on Landsat-8 images.

* Sorumlu Yazar

(onurcb@yildiz.edu.tr) ORCID ID 0000-0002-5147-747X
(tarda@yildiz.edu.tr) ORCID ID 0000-0002-4526-8727
(auzar@yildiz.edu.tr) ORCID ID 0000-0003-0873-3797

Kaynak Göster;

Bayrak O C, Arda T & Uzar M (2022). Derin Öğrenme Yöntemleri ile Uydu Görüntülerinden Orman Yangını Tespiti: Muğla Örneđi 11. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliđi (TUFUAB) Teknik Sempozyumu, 28-32, 12-14 Mayıs 2022, Mersin, Türkiye.

1. GİRİŞ

Orman yangınları, doğal yaşam alanlarını en çok etkileyen felaketlerden biri olarak kabul edilmektedir. Dünya’ da görülen orman yangınlarının %98.8’i insan kaynaklı faaliyetler sonucunda meydana gelmektedir (Şahin & Sipahioğlu, 2002). 2021 yılında Dünya genelinde 43 farklı ülkedeki orman yangınlarında 8.619 adet orman yangını sonucunda 2.6 milyon hektar alan yanarken bu sayı Türkiye’de 178 bin hektar civarı olarak bildirilmiştir (Akgül, 2021).

Orman yangınlarının meydana geldiği alanların büyüklüğü göz önünde bulundurulduğunda, bu yangınların uzaktan algılama yöntemleri kullanılarak izlenmesi yaşam alanlarının korunması açısından önemlidir (Polat & Kaya, 2021). Uzaktan algılama yöntemleri kullanılarak yanmış alanların tespit edilmesi, yangın bölgelerinin doğru belirlenmesi önem arz etmektedir. Literatürde, bitki örtüsü ve yangın tespitine yönelik geliştirilen indekslerden; Orta Kızılötesi Yangın İndeksi (Mid Infrared Burn Index (MIRBI)), Normalize Edilmiş Yanma Şiddeti İndeksi (Normalized Burn Ratio (NBR)), Normalize Edilmiş Yanma Şiddeti Fark Oranı İndeksi (Differential Normalized Burn Ratio (dNBR)), Normalize Edilmiş Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index (NDVI)) yaygın olarak orman yangınlarına yönelik hasar tespit çalışmalarında kullanılmaktadır. Bu indeksler kullanılarak farklı uydu görüntüleri ile gerçekleştirilen çalışmalarda (Lu, vd., (2015), Sabuncu & Özener (2019), Pacheca vd., (2021), Polat & Kaya (2021) tespit edilen yanmış alanlar referans veriler ile karşılaştırılarak yeşil alan kayıpları belirlenmiştir. Literatürde uzaktan algılama ile orman yangınlarına yönelik birçok farklı indeksler geliştirilmiş olsa dahi, arazi örtüsündeki çeşitliliklerden dolayı sınıf karışıklığı meydana gelebilmektedir. Bu sebeple, sınıf karışıklığı etkisinin en aza indirildiği sistemlerin kullanılması gerekmektedir. Son yıllarda gelişen yapay zeka teknolojilerini temel alan derin öğrenme yöntemleri; bilgisayarların insanlara benzer şekilde kavram hiyerarşilerinden faydalanarak karar verme sürecine dayanan makine öğrenmesi temelli yöntemler topluluğu niteliğini taşımaktadır. Derin öğrenme yöntemleri; görüntü işleme alanında obje tespiti, görüntü sınıflandırma ve segmentasyon gibi konularda yaygın olarak kullanılmaktadır (Goodfellow, vd., 2016; De Almeida vd., 2021).

Bu çalışmada, aktif yangın alanlarının belirlenmesi için Landsat-8 OLI/TIRS görüntülerinin derin öğrenme ağları ile entegrasyonu sağlanarak orman yangınlarının otomatik tespit edilmesi amaçlanmıştır. Çalışma kapsamında; açık kaynaklı bir veri setinden eğitilen modeller, 2021 yılı Ağustos ayında Muğla ilinde meydana gelen orman yangın görüntülerinde test amaçlı kullanılmıştır. Inception-V3 (Szegedy, vd., 2015) ve Xception (Chollet, 2017) ağlarının performansının karşılaştırıldığı çalışmada, derin öğrenme yöntemlerinin yanan alanların tespitinde ve izlenmesindeki doğruluk, kalite ve bütünlük performans analizi gerçekleştirilmiştir. Bu çalışmada, ikinci kısımda, kullanılan veri setleri ve yöntemler hakkında detaylar verilmiştir. Üçüncü kısımda ise görüntülere uygulanan

ön işleme adımlarını ve kullanılan derin öğrenme ağlarının hiper-parametre konfigürasyonunu içermekle birlikte, uygulama sonucunda elde edilen sayısal sonuçlar belirtilmiştir. Son kısımda, kullanılan derin öğrenme ağları arasındaki doğruluk performans sonuçları değerlendirilmiş ve doğruluğun artırılabilmesi için öneriler verilmiştir.


2. MATERYAL VE YÖNTEM

Bu çalışmada, aktarımlı öğrenme tekniğinde yaygın kullanılan açık kaynak kodlu veri setinden amaca uygun olan veri seti (Pereira, vd., 2021) kullanılmıştır. Eğitilen Inception-V3 ve Xception ağlarının performansı, 2021 yılı Ağustos ayında Muğla’da meydana gelen orman yangınlarındaki sınıflandırma performansı incelenmiştir.


2.1. Veri Seti

Ağların eğitimi için kullanılan veri seti; 2020 yılında Güney Amerika, Kuzey Amerika, Avrupa, Afrika, Asya ve Avustralya kıtalarında meydana gelen orman yangınlarının Landsat-8 OLI/TIRS görüntülerinden oluşmaktadır. Eğitim verisinin 200 GB’tan büyük olması sebebiyle sadece Güney Amerika veri seti kullanılmıştır. Ayrıca, bu veri setinin seçilmesindeki bir diğer önemli etken ise ormanlık alan yoğunluğunun fazla olmasıdır. Bu sebeple Güney Amerika veri seti kullanılarak eğitim işlemi gerçekleştirilmiştir. Şekil.1’de eğitim amaçlı kullanılan veri setinden örnek görüntüler verilmiştir.

Eğitilmiş ağların test edilmesi için USGS - Earth Explorer’dan elde edilen, 2021-Ağustos ayına ait Muğla’da meydana gelen orman yangınlarının yer aldığı görüntü kullanılmıştır (Şekil. 2). Muğla ilçesine ait Landsat-8 OLI/TIRS görüntüsünün 128x128 piksel boyutundaki parçalara bölünmesiyle birlikte toplam 3.661 adet kesit üretilmiştir. Yangın içermeyen kentsel alan, yol, ormanlık alan ve tarım arazisi sınıflarının olduğu görüntüler, ağın sadece ormanlık alandaki tespit performansının incelenmesi için veri setine dahil edilmiştir.




Şekil 1. Eğitim amaçlı kullanılan veri setinden örnek görüntüler (a: “Yangın Var”, b: “Yangın Yok” sınıfına ait görüntüler).



Şekil 2. Çalışma alanı


2.2. Inception-V3 ve Xception Ağları

Çalışma kapsamında, filtre ve havuzlama işleminin eş zamanlı yapılarak derinliğin artırıldığı Inception-V3 ve Xception ağları kullanılmıştır. Inception-V3 ağı, Inception bloklarındaki 1x1, 3x3, 5x5 ve 3x3 maksimum havuzlama işleminin paralel olarak işlenmesi aşamasından oluşmaktadır (Şekil.3). Ayrıca, bu geliştirilmiş versiyonda önceki versiyon olan Inception-V2 ağındaki küme boyutu normalizasyonu ve seyreltme (dropout) işlemleri de kullanılmaktadır. Ancak, Inception bloklarından farklı olarak, hesaplama yükünün artırması sebebiyle 5x5 konvolüsyon blokları yerine tekrarlanan 3x3 ve 1x1 boyutlarındaki konvolüsyon bloklarından oluşmaktadır.



Şekil 3. Inception-V3 blokları (Szegedy, vd., 2015 uyarlanmıştır.)

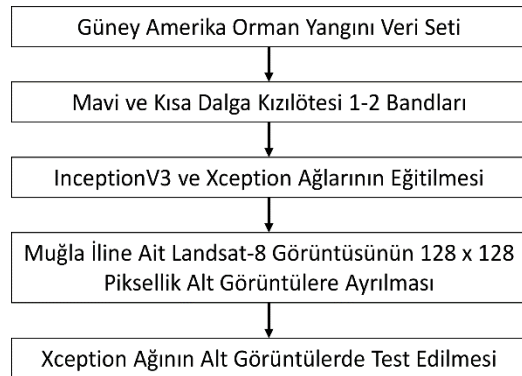
Xception ağı ise, Inception bloklarını temel alan ancak Inception bloklarından farklı olarak Derinlik Temelli Ayrıştırılabilir Konvolüsyon (Depth-wise separable convolution) bloklarını ve ResNet ağında kullanılan artık değerlerin kullanımına dayanmaktadır (Şekil. 4).



Şekil 4. Xception ağındaki blok yapısı (Chollet, 2017 uyarlanmıştır.)

3. INCEPTION-V3 ve XCEPTION AĞLARI İLE ORMAN YANGINI TESPİTİ

İlk olarak, bölüm 2.1'de detaylı bir şekilde verilen Güney Amerika orman veri seti kullanılmıştır. İkinci adımda, Mavi ve Kısa Dalga Kızılötesi 1 ve 2 bantları seçilmiştir. Üçüncü adımda, Inception-V3 ve Xception ağlarının eğitimi gerçekleştirilmiştir. Bir sonraki adımda ise çalışma alanı olan Muğla iline ait Landsat-8 görüntüsünün 128x128 piksellik alt görüntülere ayrılma işlemi uygulanmıştır. Son olarak, açık kaynaklı veri setindeki eğitim sonucunda daha başarılı olan ağ alt görüntülerde test edilmiştir. Şekil.5'de çalışmaya ait işlem adımları verilmiştir. QGIS platformu Landsat-8 görüntüsünün indirilmesinde, Python programlama dilindeki Scikit-Image (Walt, vd., 2014) ve numpy (Harris, vd., 2020) kütüphaneleri indirilen görüntülerdeki bantların seçiminde ve alt görüntülere ayırma işleminde, aktif orman yangınlarının sınıflandırılmasında derin öğrenme ağlarının eğitimi ve testi için Keras (Chollet, 2018), sonuçların sayısal analizi ise Scikit-Learn (Pedregosa, vd., 2011) kütüphaneleri kullanılmıştır.



Şekil 5. Çalışma işlem adımları

Ağların eğitimi için "Yangın Var" sınıfına ait 85.681, "Yangın Yok" sınıfına ait 108.455 adet görüntünün olduğu Güney Amerika veri setindeki görüntülerin %80'i eğitim, %20'si test amaçlı olmak üzere iki parçaya ayrılmıştır.

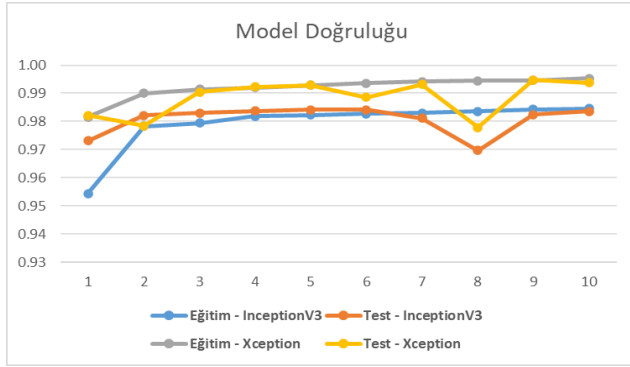
Eğitim ve test amaçlı kullanılan görüntülerde, Landsat-8 uydu görüntüsündeki Mavi ve Kısa Yakın

Kızılötesi 1-2 (Blue, SWIR-1 ve SWIR-2) bantları birleştirilerek 128x128 piksel boyutlarındaki alt görüntüler için eğitim ve test işlemi gerçekleştirilmiştir. Inception-V3 ve Xception ağlarının eğitimi için kullanılan hiper parametreler Tablo 1'de verilmiştir.

Tablo 1. Ağların eğitiminde kullanılan hiper-parametreler

| Hiper-parametreler | |
|--------------------------|----------------------|
| Epok Sayısı | 10 |
| Minimum Küme Boyutu | 16 |
| Hata Fonksiyonu | Binary Cross Entropy |
| Optimizasyon Algoritması | Adam |
| Değerlendirme Metriği | Doğruluk |
| Öğrenme Oranı | 0.001 |

Inception-V3 ağı için 6 saat 11 dakika, Xception ağı için 7 saat 4 dakika süren eğitim işlemi sonucunda; Inception-V3 ağının eğitim doğruluğu 0.985, test doğruluğu ise 0.984, Xception ağının ise eğitim ve test doğruluğu 0.995 olarak elde edilmiştir (Şekil.6).



Şekil 6. Inception-V3 ve Xception için model doğruluğu

Doğruluk (Accuracy), Bütünlük (Sensitivity), Kalite (Specificity) ve F1-Skor değerleri incelendiğinde Xception ağının Inception-V3 ağına göre daha başarılı sonuçlar ürettiği görülmüştür (Tablo.2).


Tablo 2. Inception-V3 ve Xception ağlarının açık kaynaklı veri setindeki test sonuçları

| Mimarı | Doğruluk | Bütünlük | Kalite | F1-Skor |
|-------------|----------|----------|--------|---------|
| InceptionV3 | 0.984 | 0.987 | 0.9816 | 0.9820 |
| Xception | 0.995 | 0.9947 | 0.9952 | 0.9944 |

Test için ayrılan 38.828 adet görüntüde, "Yangın Var" ve "Yangın Yok" sınıflarına ait olan görüntü sayısı sırasıyla 17.256 ve 21.572'dir. "Yangın Var" ve "Yangın Yok" sınıflarında Inception-V3 ağı 16.980 ve 21.226, Xception ağı ise 17.171 ve 21.462 adet görüntü sınıflandırılmıştır. Xception modeli, Inception-V3 modelinden daha başarılı sonuçlar ürettiğinden dolayı test görüntüsünde bu modelin çalıştırılmasına karar verilmiştir.

Xception modelinin Muğla iline ait Landsat-8 görüntüsünde çalıştırılmasıyla birlikte; %97 doğruluk, %97.4 bütünlük, %96.8 kalite ve %96.9 oranlarında F1-Skoru elde edilmiştir. Test işleminde görüntülerin Xception ağı tarafından işleme süresi yaklaşık 0.4 saniye olarak ölçülmüştür.

Şekil 7-a, Şekil 7-b ve Şekil 7-c' deki örnekler incelendiğinde, Xception ağının test görüntülerinde "Yangın Var" ve "Yangın Yok" şeklinde doğru sınıflandırma yaptığı gözlemlenmiştir.



Şekil 7. Muğla iline ait Landsat-8 görüntüsündeki Xception ağının sonuçları (a, b: "Yangın Var", c, d, e: "Yangın Yok" sınıfına ait test görüntüleri)

Şekil 7-c ve Şekil 7-d' de, su alanlarının test görüntülerine dahil olduğu bölgelerde yangın olmamasına rağmen "Yangın Var" sınıfına ait sonuç alınmıştır. Bu durumun sebebi ise kıyı alanlarındaki farklı arazi kullanım sınıflarının olması düşünülmektedir. Ek olarak, çalışmada herhangi bir arazi çalışması yapılmamasından dolayı arazi kullanımında hangi sınıfların olduğu bilinmemektedir.

4. SONUÇ ve ÖNERİLER

Çalışmada Inception-V3 ve Xception ağlarının Landsat-8 görüntülerinden aktif orman yangını belirlemedeki performansı incelenmiştir. Ağların eğitimi için açık kaynaklı bir veri seti kullanıldıktan sonra 2021 yılı Ağustos ayına ait Muğla ilinin uydu görüntüsü test amaçlı kullanılarak yangın bölgeleri test edilmiştir.

Inception-V3 ve Xception ağı, Inception blok yapısını temel alan "Ağ İçinde Ağ" (Network in Network) prensibine sahip ağlardır. Xception ağı, Inception-V3 ağına Derinlik Temelli Ayrıştırılabilir Konvolüsyon ve ResNet mimarisindeki artık blok yapısının eklenmesine sahip bir yapıdır. Çalışmada, Tablo-2 de görüldüğü üzere, açık kaynaklı veri setinin eğitiminde Xception ağı daha yüksek doğrulukta sonuçlar üretmiştir. Bu durumun, Xception ağ yapısında kullanılan Derinlik Temelli

Ayrıştırılabilir Konvolüsyon ve artık blok yapısından kaynaklandığı düşünülmektedir.

Orman yangın tespitinde öncelikle veriden bilgiye ulaşılması sürecinde hızlı ve güvenilir anlık bilgilere ihtiyaç duyulmaktadır. Yerel ve özel yönetimlerin özellikle orman alanlarının durdurulması insan ve doğal yaşamların anlık tedbirler ile korunması açısından aktarımlı öğrenme yöntemi ile uzaktan algılama verilerinin avantajı kullanıldığında başarılı bir afet ve kriz yönetimi ortaya çıkmaktadır. Bu çalışma kapsamında elde edilen doğruluk değerleri incelendiğinde olası bir yangın anında çok kısa bir süre içinde yangın alanlarının tespitinin uzaktan algılama ve derin öğrenme yöntemlerinin entegrasyonu ile başarılı bir şekilde yapılabileceği öngörülmüştür.

Yazarların Katkısı

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

Çıkar Çatışması Beyanı

Çalışmada herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

KAYNAKLAR

- Akgül O (2021). Madalyonun tek yüzü: İklim krizi ve 2021 Türkiye orman yangınları.
- Chollet F (2015). Keras. GitHub. Retrieved from <https://github.com/fchollet/keras>
- Chollet F (2017). Xception: Deep learning with depthwise separable convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- De Almeida Pereira G H, Fusioka A M, Nassu B T & Minetto R (2021). Active fire detection in Landsat-8 imagery: A large-scale dataset and a deep-learning

study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 178, 171-186.

- Goodfellow I, Bengio Y & Courville A (2016). *Deep learning*. MIT press.
- Harris C R, Millman K J, van der Walt S J, Gommers R, Virtanen P, Cournapeau D, ... & Oliphant T E (2020). Array programming with NumPy. *Nature*, 585, 357-362.
- Lu B, He Y & Tong A (2015). Evaluation of spectral indices for estimating burn severity in semiarid grasslands. *International Journal of Wildland Fire*, 25(2), 147-157.
- Pacheco, A D P, Junior J A D S, Ruiz-Armenteros A M & Henriques R F F (2021). Assessment of k-Nearest Neighbor and Random Forest classifiers for mapping forest fire areas in central Portugal using Landsat-8, Sentinel-2, and Terra Imagery. *Remote Sensing*, 13(7), 1345.
- Pedregosa F, Varoquaux Ga"el Gramfort A, Michel V, Thirion B & Grisel O (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825-2830.
- Polat N & Kaya Y (2021). Çok Bantlı Uydu Görüntüleriyle Orman Yangınlarında Hasar Tespiti. *Bartın Orman Fakültesi Dergisi*, 23 (1) , 172-181.
- Sabuncu A & Özener, H. (2019). Uzaktan Algılama Teknikleri ile Yanmış Alanların Tespiti: İzmir Seferihisar Orman Yangını Örneği. *Doğal Afetler ve Çevre Dergisi*, 5 (2), 317-326.
- Szegedy C, Vanhoucke V, Ioffe S, Shlens J & Wojna Z (2016). Rethinking the inception architecture for computer vision. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Şahin C, Sipahioğlu Ş (2002). *Doğal Afetler ve Türkiye*. Gündüz Eğitim ve Yayıncılık, Ankara.
- Van der Walt S, Sch"onberger Johannes L, Nunez-Iglesias J, Boulogne Franccois Warner J D, Yager N ... & Yu, T. (2014). scikit-image: image processing in Python. *PeerJ*, 2, e453.



© Author(s) 2022.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>