ÇOK YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİNDEN DERİN ÖĞRENME İLE ARAZİ ÖRTÜSÜ HARİTASI ÇIKARILMASI

İlyas YALÇIN¹, Gizem KARAKAŞ², Recep CAN³, Sultan KOCAMAN⁴, Sebastien SAUNIER⁵, Clement ALBINET⁶

¹Öğr. Gör., Hacettepe Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, 06909, Malıköy, Ankara, <u>ilyas.yalcin@hacettepe.edu.tr</u>
²Arş. Gör., Hacettepe Üniversitesi, Geomatik Mühendisliği Bölümü, 06800, Beytepe, Ankara, <u>gizem.karakas@hacettepe.edu.tr</u>
³Hacettepe Üniversitesi, Geomatik Mühendisliği Bölümü, 06800, Beytepe, Ankara, <u>recepcan@hacettepe.edu.tr</u>
³TÜBİTAK, Uzay Teknolojileri Araştırma Enstitüsü, 06800, ODTÜ Yerleşkesi, Ankara, <u>recep.can@tubitak.gov.tr</u>
⁴Doç. Dr., Hacettepe Üniversitesi, Geomatik Mühendisliği Bölümü, 06800, Beytepe, Ankara, <u>sultan.kocaman@hacettepe.edu.tr</u>
⁵Telespazio France, 26 Avenue Jean François Champollion, 31100 Toulouse, <u>sebastien.saunier@telespazio.com</u>
⁶European Space Agency, ESRIN, Via Galileo Galilei, 1, 00044 Frascati RM, Italy, <u>clement.albinet@esa.int</u>

ÖZET

Doğal tehlikeler, hızlı kentleşme gibi çeşitli nedenlerle yer yüzeyinde oluşan değişimlerin izlenmesi, afet yönetimi çalışmaları, kentsel alanların ve tarım arazilerinin planlanması, doğal kaynakların izlenmesi gibi çeşitli uygulamalar güncel arazi örtüsü haritalarına olan ihtiyacı arttırmıştır ve bu haritaların yüksek zamansal ve mekansal çözünürlükle üretilmesi gerekmektedir. Arazi örtüsü haritalarının üretiminde kullanılan verilerin toplama yöntemi, çalışma alanının büyüklüğü, zaman ve maliyet gibi parametreler hesaba katılarak belirlenmektedir. Bu amaçla, optik ve radar uydu görüntüleri, uzaktan algılama teknikleri ve yapay zeka algoritmalarının kullanımına literatürde artan bir sıklıkla karşılaşılmaktadır. Çok yüksek çözünürlüklü uydu görüntüleri sağlayıcılarından biri olan MAXAR Technologies, 30 cm Yer Örnekleme Aralığı (YÖA) ile elde edilen optik görüntüleri, ileri görüntü işleme yöntemleri kullanarak High Definition (HD) formatında sunmaya başlamıştır. Bu çalışmada, seçilen bir alana ait HD görüntüler kullanılarak, derin öğrenme yaklaşımı ile arazi örtüsü haritalarının üretilmesi ve doğruluğunun belirlenmesi amaçlanmıştır. Çalışma sahasında belirlenen sınıflar su yüzeyi, bitki örtüsü, asfalt, bina, gölge ve açık alanlardır. Elde edilen sonuçlar HD görüntülerin kentsel alanlarda arazi örtüsü haritası üretimi çalışmalarında kullanımının uygun olduğunu ve derin öğrenme yaklaşımlarının yüksek doğruluk sağlama potansiyelinin bulunduğunu göstermiştir.

Anahtar Sözcükler: Arazi Örtüsü Haritası, Derin Öğrenme, Görüntü Sınıflandırma, MAXAR HD

ABSTRACT

LAND COVER MAP PRODUCTION WITH DEEP LEARNING FROM VERY HIGH RESOLUTION SATELLITE IMAGERY

Various applications such as monitoring the changes on Earth's surface caused by natural hazards, rapid urbanization, etc., disaster management, planning of urban areas and agricultural lands, monitoring of natural resources have increased the need for up-to-date land cover maps and these maps must be produced with high temporal and spatial resolution. The data collection method used in the production of these maps is determined by taking into account the parameters such as the size of the study area, time and cost. For this purpose, the use of optical and radar satellite images, remote sensing techniques and artificial intelligence algorithms appear with an increasing frequency in the literature. MAXAR Technologies, one of the very high resolution satellite data providers, has started to offer images in High Definition (HD) format obtained from 30 cm Ground Sampling Distance (GSD) using advanced image processing methods. In this study, it was aimed to produce land cover maps with a deep learning approach using HD images of a selected study area. The defined classes were water surface, vegetation, asphalt, building, shade and open areas. The results showed that HD images are useful in land cover map production studies in urban areas and high classification accuracy can be obtained from the deep learning methods.

Keywords: Land Cover Map, Deep Learning, Image Classification, MAXAR HD

1. GİRİŞ

Ormanlar, su kaynakları, tarım, kentsel alanlar gibi doğal kaynaklar, yaşanabilir alanların planlanması ve sürdürülebilirliğin sağlanması için güncel arazi kullanımı ve arazi örtüsü haritalarına ihtiyaç vardır. Uzaktan algılama tekniklerinin kullanılması ile birlikte bu haritaların üretilmesi kolaylaşmıştır. Arazi örtüsü haritaları, kentsel alanların düzenlenmesi (Zhang vd., 2018), doğal tehlikelerin takip edilmesi (Karakaş vd., 2021) gibi birçok çalışmada önemli yer tutmaktadır. Yakın zamanda literatürde yer alan çalışmalar incelendiğinde, arazi örtüsü haritalarının derin öğrenme yöntemleri ile üretilmesinin güncel bir araştırma alanı haline geldiği görülmüştür (Zhang vd., 2018; Luo ve Ji 2022; Zaabar vd., 2022). Özellikle son zamanlarda sınıflandırma problemlerinde derin öğrenme yöntemlerinden evrişimsel sinir ağları (Convolutional neural networks - CNN) sıklıkla kullanılmaktadır. Hu vd. (2015) tarafından yapılan çalışmada yüksek çözünürlüklü uzaktan algılama görüntülerinden farklı arazileri sınıflandırmak için önceden eğitilmiş CNN modellerinden özelliklerin nasıl aktarılacağı araştırılmıştır. Farklı katmanlara göre CNN özelliklerini çıkarmak için iki senaryo önerilmiştir.

Längkvist vd. (2016) 0,5 m çözünürlüğe sahip gerçek renkli hava görüntülerini sayısal yüzey modeli ile birlikte bitki örtüsü, zemin, yol, bina ve su dahil olmak üzere beş arazi örtüsü sınıfında sınıflandırmak için piksel tabanlı CNN modeli kullanmışlardır. Geliştirilen modele ilişkin doğruluk skoru olarak %94 bulunmuştur. Çalışmada CNN modeli için kullanılan maske, kümeleme algoritmaları ile üretilen görüntü segmentasyonu ile oluşturulmuştur. Zhang vd. (2018) hem kentsel hem de kırsal alanda çok yüksek konumsal çözünürlüklü hava görüntülerini çok katmanlı algılayıcı ve CNN modellerini kombine ederek sınıflandırmışlardır. Çalışmada elde edilen doğruluk ise %84'tür. Zhu vd. (2021) yapmış oldukları çalışmada, Landsat 4/5, Landsat 8 ve Sentinel-2 görüntülerinin CNN kullanarak arazi örtüsü haritası üretmişler ve önerilen yöntemin sınıflandırma doğruluğunu arttırdığı sonucuna ulaşmışlardır. Yalcin vd. (2022) tarafından yapılan bir diğer çalışmada ise, HD görüntüler, rastgele orman ve destek vektör makinesi yöntemleri kullanılarak sınıflandırılmış ve farklı sahalarda %97 ve üzerinde doğruluk elde edilmiştir.

Avrupa Uzay Ajansı (ESA), ulusal uzay ajanslarının yanı sıra ticari faaliyetlerde bulunan kuruluşlar arasında işbirliğini geliştirmek amacıyla Earthnet Data Assessment Pilot (EDAP) projesini geliştirmiş (ESA, 2022) ve çeşitli uyduların verileri üzerinde erken zamanlı kalite değerlendirmeleri yapmak için standartlar oluşturmuştur. Bu bağlamda, SkySat (Saunier vd., 2022), MAXAR (Yalçın ve diğerleri, 2021, 2022) gibi uydulardan elde edilen görüntüler EDAP kapsamında değerlendirilmektedir. Bu çalışmada, EDAP kapsamında elde edilen MAXAR HD görüntüleri kullanılarak derin öğrenme yöntemi ile Cebelitarık test alanında arazi örtüsü haritası üretilmiştir. Derin öğrenme yaklaşımının geliştirilmesinde U-Net mimarisi kullanılmıştır. Veri seti, metodolojik detaylar ve sonuçlar aşağıdaki bölümlerde sunulmaktadır.

2. YÖNTEM VE VERİLER

2.1. Çalışma Alanı ve Veri Seti

Cebelitarık, Avrupa kıtasında bulunan İber Yarımadasının güneyinde ve Akdeniz kıyısında bulunmaktadır. Bölge; bitki örtüsü, yerleşim alanı ve açık alan ile beraber yoğun şekilde su kütlesi içermektedir. Yaklaşık olarak 1,51 km² alana sahip olan bölgenin konumu ve kullanılan Worldview-3 (WV3) uydu görüntüsü Şekil 1'de gösterilmektedir.



Şekil 1. Cebelitarık çalışma alanı

Çalışmada kullanılan HD görüntü, MAXAR Technologies firmasına ait WorldView-3 uydusundan elde edilmiştir. Veri setine ait bilgiler Çizelge 1'de sunulmuştur. Çizelge 1'de yer alan LV2A ürün seviyesi, görüntülere mekansal referanslamanın yapıldığı anlamına gelmektedir.

Çizelge 1. Arazi örtüsü haritası üretiminde kullanılan MAXAR veri setinin özellikleri

Çalışma Alanı	Çekim Tarihi	Ürün Seviyesi	Bantlar	Piksel boyutu
Cebelitarık	24 Kasım 2019, 11:33	LV2A (ORStandart2A)	Multispektral (Kırmızı, Yeşil, Mavi, Yakın Kızılötesi)	15 cm

2.2. Uygulama

Çalışmada kullanılan U-Net mimarisi (Ronneberger vd., 2015), kodlayıcı kısmında Squeeze-and-Excitation (SE) SE-ResNet-18 (Hu vd., 2017) ve kod çözücü kısmında transpose konvolüsyon katmanı tercih edilerek modifiye edilmiştir. Girdi görüntüleri 256 x 256 boyutunda Kırmızı-Yeşil-Mavi (Red-Green-Blue; RGB) bandlarının yanında bir bitki endeksi olan Normalized Difference Vegetation Index (NDVI) ek bandı eklenerek 4 kanal şeklinde oluşturulmuş olup, 1024 adet pencereye bölünmüştür. Bu pencerelerin %10'u test verisi olarak kullanılırken, geriye kalan görüntüler kendi içerisinde %90 (eğitim) ve %10 (validasyon) oranında iki sete ayrılarak model eğitiminde kullanılmıştır. Bu çalışmada önceden eğitilmiş model kullanılmamış, model ağırlıklarına ilk değerler rastgele olarak atanmıştır. Kategorik değişkene sahip olan bu modelin gerçek değere yakınlığını ölçmek için Kategorik Çapraz Entropi (Categorical Cross Entropy) ve Zar Kaybı (Dice Loss) kombinasyonu, optimizer olarak ise Stokastik Gradyan İnişi (Stochastic Gradient Descent) kullanılmıştır. Modelin doğruluğunun istatistiksel olarak hesaplanması için F1 skoru dikkate alınmış, ayrıca hassasiyet (precision) ve geri alma (recall) değerleri de sunulmuştur. Çalışmada değerlendirilen saha için 7 adet arazi örtüsü sınıfı belirlenmiştir. Bu sınıflar sırası ile; su, bitki örtüsü, asfalt, gölge, bina_1, bina_2 ve açık alandan oluşmaktadır.

3. SONUÇLAR

Bu çalışmada derin öğrenme yöntemi ile WV-3 HD uydu görüntüsü kullanılarak arazi örtüsü haritası üretilmiştir. 7 farklı arazi örtüsü sınıfı üzerinde uygulanan derin öğrenme modelinin test verisinde elde edilen sınıflandırma doğruluğu %87 olarak elde edilmiştir. Test veri setinde her bir sınıfa ait metrikleri içeren sınıflandırma raporu Çizelge 2' de verilmiştir. En yüksek F-1 değerleri su ve bitki örtüsü sınıflarında elde edilmiştir. En düşük değer ise açık alan sınıfında gözlemlenmiştir.

Sınıf	Hassasiyet	Geri Alma	F1-Skor	Piksel Sayısı
Su	0,99	0,93	0,96	991.714
Bitki Örtüsü	0,95	0,97	0,96	2.591.287
Asfalt	0,75	0,72	0,73	845.059
Gölge	0,81	0,88	0,84	1.006.727
Bina_1	0,75	0,71	0,73	406.347
Bina_2	0,76	0,70	0,73	715.228
Açık Alan	0,55	0,65	0,60	128.310
S	ınıflandırma Doğruluğ	0,87	6684672	

Çizelge 2. Test veri setine ait sınıflandırma raporu

Model 100 epok olarak eğitilmiş olup, eğitim ve validasyon veri setinde elde edilen F1 skorunu ve kayıp değerlerini gösteren grafikler Şekil 2' de gösterilmiştir. Şekil 2'de sunulan eğitim ve validasyon veri seti grafik uyumu, modelin eğitim setine aşırı uyum göstermediğini ortaya çıkarmıştır. Ayrıca modelin test edilmesinde kullanılan maske, model tahmini ve test alanına ait uydu görüntüsünü içeren sonuçlar Şekil 3'de sunulmaktadır.



Şekil 2. a) Model F1-skor grafiği b) Kayıp değeri grafiği



Şekil 3. Derin öğrenme modelinden elde edilen sınıflama sonuçlarına test verisinden alınan örnekler.

Maske ile karşılaştırıldığında model tahminlerinin daha genelleştiği Şekil 3'te görülmektedir. Şekil 3-C'de binaların daha düzgün şekilde olduğu ve birbiri içerisine karışan piksel sınıflarının daha az olduğu (Şekil 3-F) görülmektedir. Asfalt sınıfı üzerindeki çizgi detaylarının model tahmininde bulunmadığı Şekil 3-D'de tespit edilmiştir. Derin öğrenme modellerinin arazi kullanım-arazi örtüsü haritalarının üretimi için kullanılabilirliğinin elde edilen sonuçlar çerçevesinde uygun olduğu düşünülebilir. Bu çalışmanın sonuçları, literatürde yüksek çözünürlüklü verilerle yapılan diğer uygulamalardaki sonuçlar ile benzer bulunmuştur.

TEŞEKKÜR

Yazarlar, çalışmayı Earthnet Data Assessment Pilot (EDAP) proje kapsamında destekleyen Avrupa Uzay Ajansı (European Space Agency - ESA) ve uydu görüntülerinin sağlayan MAXAR Technologies firmasına teşekkür ederler.

KAYNAKLAR

European Space Agency (ESA), 2022. https://earth.esa.int/eogateway/activities/edap (31.10.2022 tarihinde erişildi)

Hu, F., Xia, G.-S., Hu, J., Zhang, L., 2015. Transferring Deep Convolutional Neural Networks for the Scene Classification of High-Resolution Remote Sensing Imagery. *Remote Sensing*, 7, 14680-14707. DOI:10.3390/rs71114680.

Hu, J., Shen, L. ve Sun, G., 2017. Squeeze-and-excitation networks. arXiv preprint arXiv:1709.01507, 2017. https://arxiv.org/abs/1709.01507

Karakas, G., Nefeslioglu, H.A., Kocaman, S., Buyukdemircioglu, M., Yurur, M.T. ve Gokceoglu, C., 2021. Derivation of earthquake-induced landslide distribution using aerial photogrammetry: the 24 January 2020 Elazig (Turkey) Earthquake. Landslides, 18:2193-2209. DOI:10.1007/s10346021-01660-2.

Längkvist, M., Kiselev, A., Alirezaie, M., Loutfi, A., 2016. Classification and Segmentation of Satellite Orthoimagery Using Convolutional Neural Networks. *Remote Sensing*, *8*, 329.DOI:10.3390/rs8040329.

Luo, M. ve Ji, S., 2022. Cross-spatiotemporal land-cover classification from VHR remote sensing images with deep learning based domain adaptation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 191:105-128. DOI: 10.1016/j.isprsjprs.2022.07.011.

Ronneberger, O., Fischer, P. ve Brox, T., 2015, Ekim. U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.

Saunier, S., Karakas, G., Yalcin, I., Done, F., Mannan, R., Albinet, C., Goryl, P. ve Kocaman, S., 2022. SkySat Data Quality Assessment within the EDAP Framework. Remote Sensing, 14(7):1646. DOI:10.3390/rs14071646.

Yalcin, I., Kocaman, S., Saunier, S. ve Albinet, C., 2021, Radiometric Quality Assessment for Maxar HD Imagery. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIII-B3, 797-804. DOI:10.5194/isprs-archives-XLIII-B3-2021-797-2021

Yalcin, I., Karakas, G., Kocaman, S., Saunier, S. ve Albinet, C., 2022. Investigations On The Effect Of HD Processing In Land Cover Classification. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLIII-B1-2022, 293–300. DOI:10.5194/isprs-archives-XLIII-B1-2022-293-2022.

Zaabar, N., Niculescu, S. ve Kamel, M.M., 2022. Application of Convolutional Neural Networks With Object-Based Image Analysis for Land Cover and Land Use Mapping in Coastal Areas: A Case Study in Ain Témouchent, Algeria. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15:5177-5189. DOI: 10.1109/JSTARS.2022.3185185.

Zhang, C., Pan, X., Li, H., Gardiner, A., Sargent, I., Hare, J., Atkinson, P.M., 2018. A hybrid MLP-CNN classifier for very fine resolution remotely sensed image classification. *ISPRS J. Photogramm. Remote Sensing*, 140, 133–144. DOI: 10.1016/j.isprsjprs.2017.07.014.

Zhang, P., Ke, Y., Zhang, Z., Wang, M., Li, P. ve Zhang, S., 2018. Urban Land Use and Land Cover Classification Using NovelDeep Learning Models Based on High Spatial ResolutionSatellite Imagery. *Sensors*, 18:3717. DOI:10.3390/s18113717.

Zhu, Y., Geiß, C. ve So, E., 2021. Image super-resolution with dense-sampling residual channel-spatial attention networks for multi-temporal remote sensing image classification. *International Journal of Applied Earth Observation and Geoinformation*, 104, 102543. DOI:10.1016/j.jag.2021.102543.