



## Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması

Mustafa Emre Döş<sup>1\*</sup>, Murat Uysal<sup>1</sup>

<sup>1</sup>Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Afyonkarahisar

### ÖZ

#### Anahtar Kelimeler:

Uzaktan Algılama  
Sınıflandırma  
Derin Öğrenme  
Ortofoto

Günümüzde teknolojinin hızlı bir şekilde ilerlemesi ile birlikte yaşadığımız çevre hakkında farklı platformlardaki araçlardan faydalanarak detaylı bilgiler elde edilmektedir. Konumsal veri üretiminde hava ve uydu platformlarından elde edilen görüntüler kullanılmaktadır. Bu görüntüler bitki örtüsü tespitinden, doğal afetler ve şehir planlamasına kadar birçok alanda kullanılmaktadır. Uzaktan algılama verilerindeki yüksek çözünürlüklü görüntüler sayesinde insan yapımı yapay unsurların tespitinde kolaylaşmıştır. Ancak yüksek çözünürlüklü verilerinin sunduğu bu avantajların yanında yoğun ayrıntı içeriği nedeni ile sınıflandırmada işlemlerinde insan becerisi ve müdahalesine duyulan gereksinimin fazlalığı günümüzde önemli sorunlardan biri olarak karşımıza çıkmaktadır. Günümüze kadar insan faktörünün azaltılmasına yönelik birçok sınıflandırma yaklaşımı sunulmuştur.

Daha önceden bilgisayar teknolojisinde yeterli olmayan donanımsal ve yazılımsal araçlardan dolayı, yapay zekanın temelleri sayılan makine öğrenmesi ve derin öğrenme gibi konular pek incelenmemiştir. Ancak günümüzde grafik işlemcilerde ve yazılımlardaki ilerlemeler sayesinde popülerliğini arttırmıştır. Son çalışmalarındaki performansı ile derin öğrenme yaklaşımı, makine öğrenmesinden ziyade daha umut vericidir. Bu çalışmada mevcutta bulunan sınıflandırma yöntemlerine alternatif olacak derin öğrenme algoritmalarını kullanarak sınıflandırma yapılmıştır. Algoritmanın test edilmesi için Uluslararası Fotogrametri ve Uzaktan Algılama Topluluğu (UFUAT)' dan temin edilmiş Vaihingen veri seti kullanılmıştır. Kullanılan veri setinden zemin, bina, ağaç, bitki örtüsü ve araç olacak şekilde 5 tane detay sınıfı seçilmiştir. Bu detaylardan algoritma en yüksek olarak bina sınıfına ait olanları ortalama %99 seviyesinde, en düşük olarak araç sınıfına ait detayları ortalama %95 olarak belirlemiştir. Bu çalışmadan elde edilen sonuçlarla, uzaktan algılama verilerinin otomatik sınıflandırılmasında derin öğrenme algoritmalarının iyi bir alternatif olduğu görülmektedir.

## Classification of remote sensing data with deep learning algorithms

### ABSTRACT

#### Keywords:

Remote sensing  
Classification  
Deep Learning  
Orthophoto

Today, with the rapid progress of technology, detailed information is obtained by using tools on different platforms about the environment we live in. Images obtained from air and satellite platforms are used in the production of spatial data. These images are used in many areas, from vegetation detection to natural disasters and urban planning. High resolution images in remote sensing data make it easier to detect artifacts. However, in addition to these advantages of high-resolution data, the need for human skill and intervention in the classification process is one of the biggest challenges today due to its comprehensive detail content. To date, many classification approaches have been introduced to reduce human factor.

Due to the hardware and software tools previously insufficient in computer technology, subjects such as machine learning and deep learning which are accepted as the foundations of artificial intelligence have not been studied much. However, today it has increased in popularity thanks to improvements in graphics processors and software. The performance and deep learning approach in recent studies is more promising than machine learning. In this study, classification is made by using deep learning algorithms which will be an alternative to existing classification methods. The International Photogrammetry Society and the Remote Sensing Society (ISPRS) Vaihingen data were used to test the algorithm. In the data set, 5 detail classes have been selected as ground, building, tree, vegetation and vehicle. The algorithm for these details is on average 99% and the lowest 95%. According to the results of this study, it is seen that deep learning algorithms are a good alternative for automatic classification of distance learning data.

\*Sorumlu Yazar

Kaynak Göster(APA);

(mustafaemredos@gmail.com) ORCID ID 0000-0002-7605-4270  
(muysal@aku.edu.tr) ORCID ID 0000-0001-5202-4387

DÖŞ, M., UYSAL, M. (2019). Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması. *Türkiye Uzaktan Algılama Dergisi*, 1 (1), 28-34. Retrieved from <https://dergipark.org.tr/tr/pub/tuzal/issue/50531/648988>

Araştırma Makalesi  
DOI: XXXXXXXXXXXXX


Geliş Tarihi: 20/11/2019; Kabul Tarihi: 10/12/2019

## 1. GİRİŞ

İnsanoğlu geçmişten beri çevresindeki yapılardan ve olaylardan etkilenmiş, bunlara ait bilgileri elde etmeye çalışmıştır. Bu bilgileri elde ederken ise farklı disiplinlerdeki bilim alanlarını kullanmıştır. Uzaktan algılama ile hava ve uydu platformlarındaki algılayıcılar ile elde edilen verilerin değerlendirilmesi ile nesne ve çevresi hakkında güvenilir bilgiler elde edilmektedir. Teknolojideki ilerlemeler sayesinde daha yüksek çözünürlüklü elde edilen verilerin değerlendirilmesi ve sınıflandırılmasında önemli sıkıntıların yaşanmasına sebep olmuştur. Bu verilerin değerlendirilmesi için farklı yöntemlere ve donanımlara duyulan ihtiyaç her geçen gün artmaktadır.


Günümüzde popülerliği gittikçe artan ve birçok alanda sorunların çözümünde yapay sinir ağları, makine öğrenmesi ve alt dalı olan derin öğrenme yapıları yaygın bir şekilde kullanılmaktadır. Bu çalışmada derin öğrenme yapıları, hava ve uydu görüntülerinin sınıflandırılması sorununa alternatif bir çözüm yolu olarak sunulmuştur.

Yapay sinir ağları yeni değıllerdir. İlk olarak Rosenblatt'ın yapay nöronları (Perceptron) ile ortaya çıkmıştır (Şekil 1.) (Rosenblatt, F., 1958).



Şekil 1. Yapay nöron (Perceptron) modeli

Çok katmanlı yapay nöronlar ile ilk genel öğrenme yapısı çalışmaları Ivakhnenko ve Lapa tarafından yapılmıştır. Bu çalışmalarda en iyi sonucu veren hücreler bir sonraki katmanda bulunan hücrelere alınarak sadece ileri yayılım kullanılmıştır (Şekil 2.) (Ivakhnenko, A., G., 1966).



Şekil 2. Ivakhnenko'nun çoklu yapay nöron ağı (Dettmers, T. 2015)

Daha sonra derin öğrenme yapısı ile alakalı genel olarak ilk başarılı çalışmayı Yann LeCun ve

arkadaşları posta kutusu yazıları üzerinde geliştirmişlerdir. Bu çalışmada eğitim 3 gün sürmüştür ve pratikte uygun olmadığı görülmüştür (LeCun, Y., ve ark., 1989). Yann LeCun, günümüzde programlamaya girişte ilk olarak öğretilen "Hello World" komutu ile derin öğrenme yapısındaki karşılığı olan MNIST veri setini sınıflandırmak için kıvrımlı ağlarla geri yayılımı birlikte kullanmıştır (LeCun, Y., ve ark., 1989). Ancak bu çalışmalar bilgisayarlardaki donanımsal eksikliklerden ve küçük veri setlerinden dolayı uzun süren eğitimler sonrasında istenilen doğrulukta sonuç ürünleri vermemiştir. Buna karşın Destek Vektör Makineleri (DVM) o zamandaki sorunlara daha iyi çözümler üretiyor ve daha iyi sonuçlar vermişlerdir.

2000'lerden sonra gelişen bilgisayar teknolojisi ile Grafik İşlemci Birimlerinin (GİB) kullanılmasına başlanmasıyla Makine Öğrenmesi yapıları tekrar gündeme gelmiştir. Makine öğrenmesi ile ilgili birçok çalışma yapılmıştır.

Gün geçtikçe teknolojinin gelişmesiyle çevremizdeki doğal ve yapay objeleri algılama ve kayıt etme araçlarımız gelişti. Gelişen araçlar sayesinde, farklı platformlardan yoğun ve çeşitli verilere sahip olunmaktadır. Günümüzde uzaktan algılamada kullanılan objelere ait görüntüler ise içerisinde birçok detaya sahiptir. Bu detay yoğunluğu nedeni ile verilerin elde edilmesi kadar bu verilerin sınıflandırılıp ardından yorumlanması da bir o kadar önem arz etmektedir. Sınıflandırma işleminde hem zamandan hem de maddi tasarruf yapmak için, insan etkisinin mümkün olduğunca azaltılıp işlemin otomatik olarak yapılması arzu edilir. Bu konuda Huang DVM kullanarak uzaktan algılama verisini 7 sınıfa ayırıp incelemiştir (Huang ve ark., 2002.). Daha sonra Kavzoğlu ve Çölkesen 2010 yılında yaptıkları çalışma ile Karar Ağacı (KA) yöntemi ile En Çok Benzerlik (EÇB) yöntemi karşılaştırmıştır. Makine öğrenmesi yöntemi olan KA ile daha iyi sonuçlar alınmıştır (Kavzoğlu, T. ve Çölkesen, İ., 2010). Zhang Z. ve arkadaşları CNN algoritmaları ile uzaktan algılama verilerinde çoklu model farklılıklarının karşılaştırmışlardır (Zhang, Z. ve Vosselman, G. 2018.). Makine öğrenmesi yöntemleri uzaktan algılama verilerinin sınıflandırılmasında iyi bir alternatif olarak görülmektedir. Ancak kullanıcıya bağımlılıktan kurtulma hala istenildiği seviyede değildir. Bu yüzden yeni bir yaklaşım olarak derin öğrenme yapısı karşımıza çıkmaktadır.

Bu çalışmada uzaktan algılama verilerinin hızlı ve yüksek doğrulukla otomatik sınıflandırılması için güncel bir alternatif olan derin öğrenme algoritmaları incelenmiştir. Bu kapsamda Vaihtingen veri seti kullanılarak bir şehirde havadan görüntülenebilecek detayların tespit edilip sınıflandırılması için derin öğrenme algoritmaları ile ne kadar süre aldığı ve ne kadar doğruluk elde edileceği tespit edilmeye çalışılmıştır.


## 2. YÖNTEM

Son zamanlarda bilgisayar teknolojisindeki gelişme hızı ile orantılı olarak yapay görüş ve yapay öğrenme alanlarında da gelişmeler olmuştur. Bu çalışmalarda popüler olarak derin öğrenme kullanılmaktadır. Derin öğrenme ile makine öğrenmesi arasında önemli bazı farklılıklar olsa da temelde aynı şeyleri ifade ederler. Derin öğrenme, makine öğrenmesinin bir alt kategorisidir(Şekil 3.). Makine öğrenmesi teknikleri ile ilk başlarda iyi sonuçlar elde edilmiştir. Ancak 2010 yılından itibaren artan veri seti boyutları nedeni ile klasik makine öğrenmesi kullanılarak yapılan çalışmalarda istenilen gelişmeler sağlanamamıştır.



Şekil 3. Derin öğrenme ve makine öğrenmesi arasındaki ilişki


Derin öğrenme yapısı günümüzde oldukça popülerdir. Aslında derin öğrenme yapıları yeni gibi görünse de temeli eskiye dayanmaktadır. Genel olarak bakıldığında derin öğrenme ağ yapısı ile makine öğrenmesi ağ yapısı birbirine benzerler. Ancak temelde özellik çıkarımı makine öğrenmesinde kullanıcı tarafından belirlenmekte bu da özellik görüşünü kısıtlamaktadır(Şekil 4.). İnsan yapısındaki kusurlardan dolayı ortaya çıkan bu kısıtlamanın önüne geçmek için veri setindeki özellik haritalarının derin öğrenme yapısına sahip ağ tarafından kendisinin bulması ve bu yönde tahmin yürütmesi sağlanır.



Şekil 4. Derin öğrenme ve makine öğrenmesi arasındaki fark

Derin öğrenme yapısı ile makine öğrenmesi yapısı arasındaki bu farklılıktan dolayı, derin öğrenmede veri miktarının artması ile performans aynı seviyede kalmayıp veri miktarı ile aynı oranda artmaktadır(Şekil 5.). Günümüzde kolaylıkla birçok resim ve görüntüye sahip olunabilmektedir. Bu sayede derin öğrenme yapısı yerinde saymayıp


gelişmekte ve günümüzdeki veri bilimi alanında birçok soruna alternatif çözümler sunmaktadır.



Şekil 5. Derin öğrenme ve makine öğrenmesi arasındaki veri miktarına göre performans eğrisi

### 2.1. Evrimsel Sinir Ağları(ESA)

Derin öğrenme ile farklı bilim dallarındaki problemlere çözümler sunulmaktadır. Ancak görüntü sınıflandırması söz konusu olduğunda en iyi sonucu Evrimsel Sinir Ağı(ESA) mimarisi vermektedir. Genel olarak ESA görüntü sınıflandırılmasında kullanılır. ESA mimarisi ile alakalı ilk başarılı çalışmayı 1989 yılında LeCun ve arkadaşları LeNet-5 mimarisini kullanarak posta kutusu yazıları ve MNIST veri seti üzerinde çalışmıştır(LeCun, Y., ve ark., 1989). O dönemden sonra bu alandaki çalışmalar uzun bir süre durmuştur. Daha sonra 2012 yılında içerisinde 14 milyon resim ve bin sınıf barındıran IMAGENET yarışmasında birçok alanda birinci olan AlexNet mimarisi tekrar derin öğrenmeyi popüler hale getirmiştir(Şekil 6.) (Krizhevsky, A., ve ark., 2012).




Şekil 6. AlexNet ağ yapısı

2014 yılında ise IMAGENET yarışmasında ana kategoriyi GoogLeNet kazanmıştır(Szegedy, C., ve ark., 2014). İkinci olan VGG modelinde farklı kategorilerde önde gelmiştir. 2015 yılında bu yarışmayı 152 katmanlı çok derin bir ağ olan ResNet mimarisi kazanmıştır(Kaiming, H., ve ark., 2016).

Ancak bu mimariler hem çok ağır bir işlem yükü sunduğu için hem de amacımız kullanılan görüntülerde tek bir özelliğin çıkarılması yerine, görüntülerdeki her bir doğal veya yapay objenin kendisi ve çevresi ile korelasyonunu belirlemektir. Bu konuda derin öğrenme yapılarında semantik segmentasyon mimarileri kullanılır. Sunulan bu çalışmada derin öğrenme algoritmalarının semantik segmentasyona daha uygun hale getirmek için


tasarlanan SegNet mimarisi kullanılmıştır(Şekil 7.) (Badrinarayanan, ve ark., 2016.). SegNet mimarisi bir kodlayıcı ağına ve buna uygun çalışan çözücü ağına sahiptir. Kodlayıcı ağına ise daha önceden VGG16 mimarisi ile eğitilen ağırlık değerleri kullanılmaktadır.



Şekil 7. SegNet ağ yapısı illüstrasyonu

2012 yılında AlexNet' in başarılı sonuçlar vermesi ile derin öğrenme tekrar popüler bir hale geldi. Derin öğrenme ile etkili sonuçlar elde etmek için genel olarak iki ön koşul vardır. Bunlardan birincisi eğitim veri setinin çeşitliliği ve büyüklüğü, bir diğeri ise kullanılan bilgisayarın donanımsal olarak yüksek özellikli donanımsal parçalar(Ekran kartı, İşlemci vb.) barındırması gerekir. İşin bu kısmında maddi açıdan büyük bir yük karşımıza çıkmaktadır. Bu sorunu çözmek için derin öğrenme ve yapay zekanın geleceğe yön vereceğini düşünen Google ve Amazon gibi büyük şirketler ücretli ve ücretsiz bulut sistemleri sunmaktadır. Bu bulut sistemleri sayesinde büyük maliyetlerden kaçınılabılır.

Yapılan bu çalışmada uzaktan algılama verilerindeki sınıflandırma problemine çözüm olarak derin öğrenme yapısı sunulmaktadır. Derin öğrenme sayesinde kullanıcıya bağımlılık diğer alternatif çözüm yöntemlerine göre daha da azalmaktadır.




Şekil 8. Çalışma alanındaki eğitim ve test verilerine ait bölgeler

Bilgisayar görüşü sistemleri artık birçok alanda insan performansının üstüne çıkmaktadır. Onlardan

birisi olan derin öğrenme yapısı da mevcutta bulunan veri setlerinin sınıflandırılmasında insan faktörünün üzerine çıkmaktadır. Derin öğrenmenin bu özelliğinden dolayı çalışmada tercih edilmiştir. UFUAT' ın Vaihingen veri setini kullanarak sınıflandırma yapılmıştır. Veri setinde 3 bantlı IRGB ortofotoların 12 tanesi eğitim, 4 tanesi test verisi olarak ayrılmıştır(Şekil 8.).

Eğitim sırasında sınıflandırmanın doğruluğunu kontrol etmek için daha önceden ayrılmış gerçek zemin görüntüleri ile sonuç ürünler karşılaştırılmıştır. Objelerin sınırlarının daha keskin belirlenmesi içinde gerçek zemin görüntülerinde sınır belirginleştirme işlemi yapılarak ayrıca eğitim verilerine eklenmiştir (Şekil 9.).



Şekil 9. (a) Bölge-1 için ortofoto, (b)gerçek zemin, (c)gerçek zemin sınır belirginleştirme

Veri seti zemin, bina, bitki örtüsü, ağaç ve araba olarak 5 sınıfa ayrılmıştır. En son olarak genel bir sınıf doğruluğu tespit edilmeye çalışılmıştır. Eğitim verilerinde sınıflandırma yaparken semantik segmentasyon yapabilmek için derin öğrenme yapısındaki SegNet mimarisini kullanılmıştır. SegNet yapı olarak iki kısma ayrılır. İlk kısım kodlayıcı olarak adlandırılır, burada eğitim süresini azaltmak için VGG16 ile daha önceden belirlenmiş ağırlık değerleri ile eğitime başlanır. SegNet' in ikinci kısmına ise kod çözücü denir. Burada her bir kodlayıcı kısma uygun gelen kod çözücü kısımlar ile işleme devam edilir. Son olarak sonuç ürün için girdiler Softmax sınıflandırıcısına sokulur(Bozkurt, S., 2018).

Tüm bu eğitim ve test aşamaları yapılırken sistem GİB' in belleğinde büyük bir alan kullanılmaktadır. Bu işlem için en az 12 GB' lik bir GİB gerekmektedir. Böyle donanımsal özelliğe sahip bir GİB maliyeti oldukça yükseltir. Bundan dolayı Google'ın ücretsiz GİB desteği verdiği Colaboratory (Colab) hizmeti kullanılarak eğitim ve test aşamaları gerçekleştirilmiştir. Colab' ta Nvidia' nın Tesla k40 GİB kullanılmaktadır.

### 3. BULGULAR

Bu çalışma kapsamında veri seti 12 eğitim ve 4 test verisi olarak ikiye ayrılmış ve çalışmanın tamamı Google Colab bulut sistemi üzerinden yapılmıştır. İlk olarak eğitim veri seti üzerinden


rastgele görüntüler algoritmaya sunulmuş ve algoritma tahminine göre ağırlık değerleri düzeltilip çalışmanın eğitim kısmı bitirilmiştir. Eğitim sonunda sınıflara ait doğruluk ve kappa değerleri Tablo 1.' de gösterilmiştir.

**Tablo 1.**Eğitim setindeki sınıflara ait doğruluk ve genel doğruluk değerleri

	Zemin (%)	Bina (%)	Bitki örtüsü (%)	Ağaç (%)	Araç (%)	Genel doğruluk (%)
1	98.52	99.23	96.65	97.76	94.22	98.45
3	98.66	99.01	95.98	95.83	96.38	97.76
23	97.95	99.13	96.98	97.81	97.59	97.86
26	98.33	98.98	95.26	98.16	93.74	98.24
7	98.65	99.26	96.76	98.48	94.30	98.46
11	98.51	99.11	95.70	97.82	96.92	97.95
13	97.92	99.41	96.77	96.69	92.52	97.40
28	97.83	98.81	96.92	96.89	94.68	97.75
17	98.35	99.48	98.69	97.96	95.42	98.59
32	99.42	99.70	96.22	97.79	96.73	99.00
34	99.09	99.44	97.67	98.13	96.51	98.58
37	99.06	99.27	98.64	96.80	97.73	98.64

Tablo 1' e bakıldığında genel olarak sınıflara ait doğrulukların yüksek olduğu görülmektedir. Bunun sebebi olarak gerçek zemin görüntüsünün yanında sınıflara ait sınırların daha belirgin olduğu sınır belirginleştirme işlemi uygulanan görüntülerin kullanılmış olması olduğu düşünülmektedir. Bir başka değerlendirme olarak her bir tekrar sırasında algoritmanın kullandığı görüntü sayısı ne kadar yüksek olursa algoritma kullandığı ağırlık ve sapma değerlerine getirmesi gereken düzeltme miktarını daha doğru tahmin etmektedir. Bu sebeple Google colab' ın sunduğu Tesla k40 GIB' si ile yüksek tekrar ve her tekrar yapılırken fazla görüntü kullanılması sayesinde algoritmanın yüksek doğrulukla tahminler sunmaktadır.


Aşağıda kayıp değerlerine ait grafik üç aşamada gösterilmiştir.



**Şekil 10.** (a) Birinci eğitim için kayıp değer grafiği, (b)ikinci eğitim için kayıp grafiği, (c) Üçüncü eğitim için kayıp grafiği


Şekil 10' da sunulan grafiklerden de görülebileceği gibi daha önceden eğitilmiş VGG-16 değerleri sayesinde kayıp değer grafiği değerleri düşmeye başlamıştır. Bu sayede daha uzun sürecek bir eğitim aşamasından kaçınılmıştır. Birinci eğitimde kayıp değer grafiği 1,8 ile 0,2 gibi geniş bir sayı aralığındadır. Daha sonraki aşamalarda 0.32 ile 0.16 ve 0,3 ile 0.125 gibi dar ve uygun değer aralığında bir alanda devam etmektedir. Bundan dolayı eğitim görüntülerindeki küçük yanlış sonuç değerleri nedeni ile dalgalanmalar meydana gelmektedir.

Bu dalgalanmaların ilk sebebi olarak ortofoto görüntülerindeki gölgelerden kaynaklı piksellerin gerekli yansıma değerlerine sahip olmadıkları tespit edilmiştir(Şekil11.).



**Şekil 11.** (a)Ortofoto görüntü, (b)gerçek zemin görüntüsü, (c)algoritma tahmini

Bir diğer neden ise algoritmanın bitki örtüsü ile ağaçlık alanların iç içe geçmesinden dolayı ikisini birbirinden ayırt edememesinden kaynaklandığı düşünülmektedir (Şekil12.).



**Şekil 12.** (a)Ortofoto görüntü, (b)gerçek zemin görüntüsü, (c)algoritma tahmini

Eğitimden sonra elde edilen son ağırlık ve sapma değerleri ile daha kaba ve daha hızlı olan test aşamasına geçilmiştir. Burada veri setinden rastgele seçilen 4 tane ortofoto görüntüden test işlemi yapılmış ve Tablo 2'de sonuç değerleri sunulmuştur.

**Tablo 2.** Test setindeki sınıflara ait doğruluk ve genel doğruluk değerleri

	Zemin (%)	Bina (%)	Bitki örtüsü (%)	Ağaç (%)	Araç (%)	Genel doğruluk (%)
5	98.52	99.26	96.60	97.79	94.20	98.45
21	98.66	99.01	95.98	95.83	96.38	97.76
15	97.95	99.13	96.98	97.81	97.59	97.86
30	98.33	98.98	95.26	98.16	93.74	98.24

Tablo 2' ye bakıldığında genel doğrulukta düşüş olduğu görülmektedir. Bunun sebebi olarak algoritmanın daha hızlı tahmin yapabilmesi için daha kaba tahmin süresi verilmesi olduğu düşünülmektedir. Tablo 2 incelendiğinde zemin ve bina sınıflarının daha iyi tahmin edildiği görülmektedir. Araç sınıfının ise ortofotolardaki düşük parlaklık değerleri nedeni ile algoritma tahmini düşük olduğu düşünülmektedir.

#### 4. SONUÇLAR

Bu çalışmada uzaktan algılama verilerinin otomatik olarak derin öğrenme algoritması ile sınıflandırılması üzerine bir çalışma gerçekleştirilmiştir. Çalışmanın test kısmı için Tablo 2' de genel bölgelere bakıldığında bina ve zemin alanlarını algoritmanın yüksek seviyede tahmin sonuçları vermiş olduğu görülmektedir. 15. Bölgede araç tahmini diğerlerine göre daha iyi sonuç vermiştir. Bunun sebebi olarak araçların gölgede ve ağaçların altında kalmamış olması ve iş makinelerinin az olması sebebi ile algoritmamızın yanlış tahmin etmemesi söylenebilir. Algoritmamızın bitki örtüsünü, ağaç sınıfı ile karıştırması sebebi ile genel olarak doğruluk değeri düşmüştür. Sonuçlara bakılarak yüksek doğruluk değerleri ile algoritmanın sınıflandırma yaptığı görülmektedir. Mümkün olduğunca insan etkisinin azaltılarak uzaktan algılamadaki çalışmaların en

büyük avantajı olan maddi ve zaman açısından tasarrufu sağlayacağı düşünülmektedir. Bu durum uzaktan algılama verilerinin sınıflandırılmasında derin öğrenme yapısının ciddi bir alternatif çözüm olacağı düşünülmektedir. Bu eğitim veri setindeki görüntüler çeşitlendirilip tespit edilen eksikliklerin giderilmesi ile çok daha iyi sonuçlar elde edilebilir. Bu gibi çalışmalarda ciddi maliyet ve donanımsal özelliklere sahip bilgisayarlara ihtiyaç duyulmaktadır. Bu yapılan çalışmada Google' ın bulut sistemi olan Google Colaboratory ile tüm işlemler gerçekleştirip sonuç ürünleri elde edilmiştir. Bir sonraki yapılacak çalışmalarda bu gibi bulut sistemlerinden de yararlanılabileceğini bu çalışmada gösterilmeye çalışılmıştır.

#### KAYNAKÇA

- Audebert, N., Le Saux, B., & Lefèvre, S. (2018). Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 20-32.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481-2495.
- Bozkurt, S., 2018. Derin öğrenme algoritmaları kullanılarak çay alanlarının otomatik segmentasyonu. Yüksek lisans tezi, Yıldız Teknik Üniversitesi, FBE, İstanbul.
- Dettmers, T., 2015. Deep learning in a nutshell: history and training parallel for all. Available: <https://devblogs.nvidia.com/parallelforall/deep-learning-nutshell-history-training/>[Accessed:12-Apr-2019].
- Huang, C., Davis, L. S. and Townshend, JRG., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23, 725-749.
- Ivakhnenko, A. G., & Lapa, V. G. (1966). Cybernetic predicting devices (No. TR-EE66-5). PURDUE UNIV LAFAYETTE IND SCHOOL OF ELECTRICAL ENGINEERING.
- Kaiming, H., et al., 2016. Deep residual learning for image recognition. 2016 CVPR, Las Vegas, USA, 27-30 June 2016, pp. 770-778
- Kavzoglu, T. ve Çölkesen, İ., 2010. Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği, *Electronic Journal of Map Technologies*, Vol:2, No:1, pp 36-45

- Krizhevsky, A., Sutskever, A. and Hinton, G., E. 2012. Image Net classification with deep convolutional neural networks. Advances in neural Information processing systems 25, Nevada, Usa, 3-8 December 2012, pp 1-9
- LeCun Y., Boser B., and Denker, J., S., 1989. Hand written Digit Recognition with a Back-Propagation Network.
- LeCun, Y., et al., 1989. Backpropagation Applied to Handwritten Zip Code Recognition, *NeuralComput.*, vol. 1, no. 4, pp. 541-551, Dec.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- Zhang, Z., Vosselman, G., Gerke, M., Tuia, D., & Yang, M. Y. (2018). Change detection between multimodal remote sensing data using siamese CNN. arXiv preprint arXiv:1807.09562.