

UZAKTAN ALGILAMA VERİLERİNİN DERİN ÖĞRENME ALGORİTLARI İLE SINIFLANDIRILMASI

M.E.Döş^{a,*}, M. Uysal^a

^a Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 03200 Afyonkarahisar, Türkiye - mustafaemredos@gmail.com, muysal@aku.edu.tr,

ANAHTAR KELİMELELER: Uzaktan algılama, Sınıflandırma, Derin öğrenme, Ortofoto

ÖZET:

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 ISPRS' den temin edilmiş Vaihingen veri seti kullanılmıştır.

CLASSIFICATION OF REMOTE SENSING DATA WITH DEEP LEARNING ALGORITHMS

M.E.Döş^{a,*}, M. Uysal^a

^a Afyon Kocatepe University, Engineering Faculty, Geomatics Engineering Department, 03200 Afyonkarahisar, Turkey - mustafaemredos@gmail.com, muysal@aku.edu.tr,

KEY WORDS: Remote sensing, Classification, Deep learning, Orthophoto

ABSTRACT:

Currently, with the rapid advance of technology we can obtain information about the environment we live in by benefiting from the tools in different sources. Location information using image creating from aerial and satellite platforms. These images are used for various areas such as determining agriculture, vegetation, natural forces and city planning. Thanks to the images taken with high resolution in deep sensing data, the detection of man-made factors have become simple. However, despite the advantages high resolution data provide, due to its tense, detailed content, there needs to be human efficiency and intervention in classification, which is one of the main problems at present. Several approaches of classification have been put forward in order to decrease human effect up to present

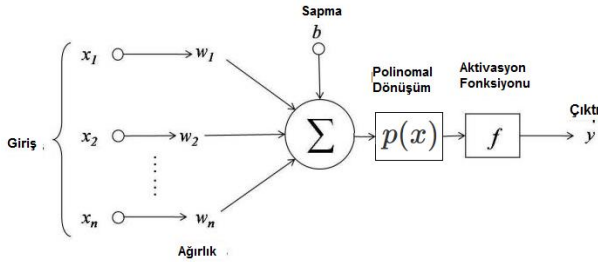
Due to the tools in computer technology that are inefficient in terms of software and hardware, machine learning and deep learning, the basic of artificial intelligence, were not researched beforehand. Nonetheless, it increased its popularity has increased with the advance of graphic processors and softwares. With its performance in latest studies, deep learning approach is more promising than machine learning. In this study, classification will be made by using deep learning algorithms as an alternative to current approaches of classification. In order to test the algorithm, Vaihingen data set, obtained from ISPRS has been used.

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 uydular 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 sıkıntılar 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 uydular görüntülerinin sınıflandırılması sorununa alternatif bir çözüm yolu olarak sunulmuştur.

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



Şekil 1. Yapay Nöron (Perceptron) Modeli

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



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

Daha sonra derin öğrenme yapısı ile alakalı genel olarak ilk başarılı çalışmayı Yann LeCun (LeCun, Y., et al., 1989) ve arkadaşları posta kutusu yazıları üzerinde geliştirmişlerdir. Bu çalışmada eğitim 3 gün sürmüştür ve pratikte uygun olmadığı görülmüştür. Yann LeCun, günümüzde programlamaya girişte ilk olarak öğretilen "Hello World" komutu ile derin öğrenme yapısındaki karşılığı olan MNIST (LeCun, Y., et al., 1989) veri

setini sınıflandırmak için kıvrımlı ağlarla geri yayılımı(Backpropagation) birlikte kullanmıştır. 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 (SVM) o zamandaki sorunlara daha iyi çözümler üretiyor ve daha iyi sonuçlar vermişlerdir.

2000'lerden sonra gelişen bilgisayar teknolojisi ile grafik işlemci birimlerinin (GPU) kullanılmaya başlanmasıyla makine öğrenmesi yapıları tekrar gündeme gelmiş ve SVM'lere rakip olmuştur. 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 oluyoruz. 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 (Huang et al., 2002.) SVM kullanarak uzaktan algılama verisini 7 sınıfa ayırıp incelemiştir. 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. Zhang Z. ve arkadaşları CNN algoritmaları ile uzaktan algılama datalarında multimodal farklılıklarının karşılaştırmışlardır (Zhang, Z. and 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.

2. DERİN ÖĞRENME

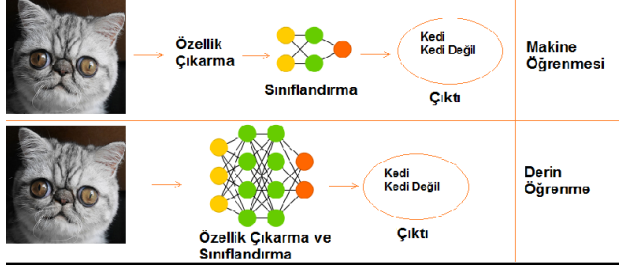


Şekil 3. Derin öğrenme ile makine öğrenmesi arasındaki ilişki

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.


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 buda 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 ile 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 ile makine öğrenmesi arasındaki veri miktarına göre performans eğrisi

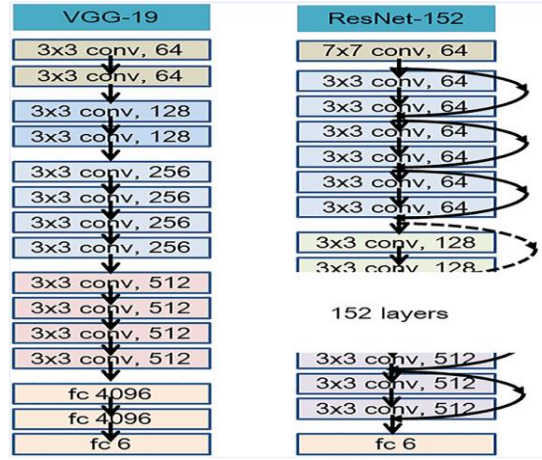
1.2.1 Evrimsel Sinir Ağları(Convolutional Neural Networks)

Derin öğrenme ile farklı bilim dallarındaki problemlere çözümler sunulmaktadır. Bundan dolayı Evrimsel Sinir Ağları(ESA), Tekrarlayan Sinir Ağları(RNN), Uzun Kısa Vadeli Hafıza Ağları, Sınırlı Boltzman Makineleri, Derin İnanç Ağları, Derin Oto-Kodlayıcılar gibi birçok derin öğrenme yapısı karşımıza çıkmaktadır. Görüntüleri sınıflandırmada en iyi sonucu ESA mimarisi vermektedir. Genel olarak ESA görüntü sınıflandırılmasında kullanılır. ESA mimarisi ile alakalı ilk başarılı çalışmayı 1998 yılında LeCun ve arkadaşları LeNet-5 mimarisini kullanarak posta kutusu yazıları ve MNIST veri seti üzerinde çalışmıştır. Daha 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 (Şekil 6.) (Krizhevsky, A., et al., 2012) mimarisi tekrar derin öğrenmeyi popüler hale getirmiştir.




Şekil 6. AlexNet ağ yapısı

2014 yılında ise IMAGENET yarışmasında ana kategoriye GoogLeNet (Szegedy, C., et al., 2014) kazanmıştır. İkinci olan VGG modelinde farklı kategorilerde önde gelmiştir. 2015 yılında bu yarışmayı 152 katmanlı çok derin bir ağ olan ResNet (Kaiming, H., et al., 2016) mimarisi kazanmıştır.(Şekil 7.)



Şekil 7. Vgg-19 ve Resnet mimarileri

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. Biz bu çalışmamızda derin öğrenme algoritmalarını semantik segmentasyon için daha uygun hale getirmek için tasarlanan SegNet (Badrinarayanan, V., Kendall, A. And Cipollo, R., 2016.) mimarisini(Şekil 8.) kullandık. Segnet mimarisi bir kodlayıcı(encoder) ağına ve buna uygun çalışan çözücü(decoder) ağına sahiptir. kodlayıcı ağında ise daha önceden VGG16 mimarisi ile eğitilen ağırlık değerleri kullanılmaktadır.




Şekil 8. SegNet ağ yapısı

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, Ram 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 kurtulabiliriz.

3. MATERYAL VE METOT


Biz bu çalışmamızda uzaktan algılama verilerindeki sınıflandırma problemine çözüm olarak derin öğrenme yapısını sunuyoruz. Derin öğrenme sayesinde kullanıcıya bağımlılık diğer alternatif çözüm yöntemlerine göre daha da azalmaktadır.

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. Bu özelliğinden dolayı çalışmamızda tercih edilmiştir. ISPRS' nin Vaihingen veri setini kullanarak sınıflandırma yapacağız. Veri setinde 3 bantlı IRGB ortofotoların 12 tanesi eğitim, 4 tanesi test verisi olarak ayrılmıştır. (Şekil 9.)



Şekil 9. Eğitim ve test verilerine ait bölgeler

Eğitim sırasında sınıflandırmanın doğruluğunu kontrol etmek için daha önceden ayrılmış gerçek zemin görüntüleri ile sonuç ürünler karşılaştırılacaktır. objelerin sınırlarının daha keskin belirlenmesi içinde gerçek zemin görüntülerinde sınır belirginleştirme işlemi yapılarak ayrıca eğitim verilerine eklenmiştir.(Şekil 10.)



Şekil 10. (a) Bölge-1 için Ortofoto, (b) Gerçek zemin, (c) Gerçek zemin sınır belirginleştirme

Veri seti zemin, bina, bitki örtüsü, ağaç, araba ve dağınıklık olarak 6 sınıfa ayrılmıştır. Burada dağınıklık sınıfı ilk 5 sınıf dışında kalan detaylardır. Eğitim verilerinde sınıflandırma yaparken semantik segmentasyon yapabilmek için derin öğrenme yapısındaki SegNet mimarisini kullandık. 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.(Bozkurt, S., 2018). 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.

Tüm bu eğitim ve test aşamaları yapılırken sistem GPU' nun belleğinde büyük bir alan kullanmaktadır. Bu işlem için en az 12 GB' lik bir GPU gerekmektedir. Böyle donanımsal özelliğe sahip bir GPU maliyeti oldukça yükseltir. Bundan dolayı Google'ın ücretsiz GPU desteği verdiği Colaboratory(Colab) hizmeti kullanılarak eğitim ve test aşamaları gerçekleştirilmiştir. Colab' ta Nvidia' nın Tesla k40 GPU kullanılmaktadır.(Şekil 11.)



Şekil 11. Tesla k40 12gb

4. SONUÇLAR VE DEĞERLENDİRME


Eğitim sonunda sınıflara ait doğruluk ve kappa değerleri Tablo 1.' de gösterilmiştir.

Bölgeler	Zemin (%)	Bina (%)	Bitki örtüsü (%)	Ağaç (%)	Araç (%)	Genel doğruluk (%)
1	98.522	99.264	96.603	97.787	94.198	98.448
3	98.664	99.010	95.987	95.827	96.385	97.758
23	97.948	99.134	96.982	97.813	97.589	97.856
26	98.328	98.977	95.263	98.158	93.745	98.245
7	98.649	99.259	96.756	98.481	94.300	98.460
11	98.511	99.105	95.699	97.823	96.918	97.952
13	97.915	99.409	96.770	96.686	92.521	97.405
28	97.829	98.813	96.919	96.888	94.675	97.747
17	98.353	99.476	98.694	97.962	95.419	98.590
32	99.416	99.703	96.222	97.794	96.729	99.004
34	99.094	99.442	97.677	98.132	96.507	98.584
37	99.064	99.273	98.643	96.802	97.734	98.643

Tablo 1. Eğitim veri setindeki sınıflara ait doğruluk, genel doğruluk

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 olmasıdır. 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 GPU' su ile yüksek tekrar (epok) ve her tekrar yapılırken fazla görüntü(batch) kullanılması sayesinde algoritmamız yüksek doğruluklu tahminler sunmaktadır.


Aşağıda kayıp (loss) değerlerine ait grafik üç aşamada gösterilmiştir.



Şekil 12. (a) Birinci eğitim için kayıp(loss) değer grafiği, (b)ikinci eğitim için kayıp grafiği, (c) Üçüncü eğitim için kayıp grafiği


Şekil 12’ de sunulan grafiklerden de görülebileceği gibi daha önceden eğitilmiş VGG-16 değerleri sayesinde kayıp değer grafiğimizin değerleri düşmeye başlamıştır. Bu sayede daha uzun sürecek bir eğitim aşamasından kurtulmuş bulunmaktayız. Birinci eğitimde kayıp değer grafiğimiz 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.



Şekil 13. (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 kaynaklanmaktadır.



Şekil 14. (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.

Bölgeler	Zemin (%)	Bina (%)	Bitki Örtüsü (%)	Ağaç (%)	Araç (%)	Genel doğruluk (%)
5	92.357	96.167	76.161	86.977	80.135	92.995
21	91.953	95.558	74.183	92.471	76.136	90.492
15	87.190	95.422	79.622	88.576	92.584	87.508
30	90.975	94.470	79.864	88.614	82.873	89.058

Tablo 2. Test verisi için sınıfların doğruluk değerleri, genel doğruluk değerleri

Bu çalışmamızda uzaktan algılama verilerinin otomatik olarak derin öğrenme algoritması ile sınıflandırılması üzerine bir çalışma gerçekleştirdik. Çalışmamızın test kısmında Tablo 2’ de genel bölgelere bakıldığında bina ve zemin alanlarının algoritmamız yüksek seviyede tahmin etmiştir. 15. Bölgede araç tahmini değerlerine 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 algoritmamızın sınıflandırma yaptığını görmekteyiz. Mümkün olduğunca insan etkisinin azaltılarak uzaktan algılamada ki çalışmaların en büyük avantajı olan maddi ve zaman açısından tasarrufa sağlanmıştır. Bu durum bize uzaktan algılama verilerinin sınıflandırılmasında derin öğrenme yapısının ciddi bir alternatif çözüm olduğu sonucuna götürmektedir. 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. Biz yaptığımız çalışmada Google’ ın bulut sistemi olan Google Colaboratory ile tüm işlemlerimizi gerçekleştirip sonuç ürünleri elde ettik. Bir sonraki yapılacak çalışmalarda bu gibi bulut sistemlerinden de yararlanılabileceğini çalışmamızda göstermeye çalıştık.

5. KAYNAKÇA

Rosenblatt, F., 1958. The Perceptron: A probabilistic model for information storage and organization in the brain. In: *Psychological Review*, Cornell aeronautical laboratory, New York, USA, Vol. LXV, No. 6, pp 386-408.

Ivakhnenko, A.,G. and Lapa, V.,G. 1966. Cybernetic predicting devices.

Dettmers, T., 2015. Deep learning in a nutshell: history and training parallel forall. Available: <https://devblogs.nvidia.com/parallelforall/deep-learning-nutshell-history-training/>[Accessed: 12-Apr-2019].

LeCun, Y., et al., 1989. Backpropagation Applied to Handwritten Zip Code Recognition, *Neural Comput.*, vol. 1, no. 4, pp. 541–551, Dec.

LeCun Y., Boser B., and Denker, J., S., 1989. Handwritten Digit Recognition with a Back-Propagation Network.

Huang, C., Davis, L. S. and Townshed, JRG., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23, 725–749.

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. ImageNet classification with deep convolutional neural networks. *Advances in neural Information processing systems*25, Nevada, Usa, 3-8 December 2012, pp 1-9

Szegedy, C., et al., 2014. Going deeper with convolutions.

Kaiming, H., et al., 2016. Deep residual learning for image recognition. 2016 CVPR, Las Vegas, USA, 27-30 June 2016, pp. 770-778

Badrinarayanan, V., Kendall, A. And Cipollo, R., 2016. SegNet: A deep convolution encoder-decoder architecture for image segmentation.

Zhang, Z., Vosselman, G., Gerke, M., Tuia, D. and Yang, M., Y, 2018. Change detection between multimodal remote sensing data using siamese cnn

Audebert, N., Le Saux, B. and Lefevre, S., 2018. Beyond rgb: Very high resolution urban remote sensing with multimodal deep networks. *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol: 140, pp. 20-32

Bozkurt, S., 2018. Derin öğrenme algoritmaları kullanılarak çay alanlarının otomatik segmentasyonu. Yüksek lisans tezi, Yıldız Teknik Üniversitesi,.