

FOTOGRAMETRİK NOKTA BULUTLARINDAN MAKİNE ÖĞRENMESİ YÖNTEMİ İLE BİNA ÇIKARIMI

Onur Can BAYRAK¹, Melis UZAR²

¹Arş.Gör., Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, 34220, İstanbul, onurcb@yildiz.edu.tr

²Doç. Dr., Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, 34220, İstanbul, auzar@yildiz.edu.tr

ÖZET

Fotogrametrik yöntemlerle üretilen nokta bulutları, objelere ait renk ve 3 boyutlu konum bilgisini içermesi sayesinde yeryüzüne ait karakteristiklerin gösteriminde kullanılmaktadır. Ancak üretilen nokta bulutlarındaki arazi kullanım sınıflarının tespit edilebilmesi için 3 boyutlu sayısallaştırma işleminin yapılması gerekmektedir. Bu işlemin zaman alıcı olması ve hedef bölgenin boyutuna göre donanım problemleri ile karşılaşılmasından dolayı hedef objelere ait otomatik çıkarım yapılması, iş gücü ve dökümantasyon açısından önemlidir. Gelişmekte olan makine öğrenmesi algoritmaları sayesinde elde edilen verilerin sınıflandırılması, fotogrametrik nokta bulutlarındaki objelerin çıkarımı için kullanılabilir. Bu çalışma kapsamında, makine öğrenmesi temelli bir sınıflandırma algoritması olan Rastgele Orman (RO) sınıflandırıcısının, açık kaynaklı bir kentsel alan veri setindeki bina çıkarım performansı incelenerek, RO sınıflandırıcısı tarafından seçilen en etkili parametreler incelenmiştir. Test işlemi sonucunda 0.816 Doğruluk, 0.7916 Bütünlük, 0.9021 Kalite ve 0.8702 F1-Skor' u elde edilmiştir.

Anahtar Sözcükler: Nokta Bulutu, Makine Öğrenmesi, Sınıflandırma, Bina Çıkarımı.

MACHINE LEARNING-BASED BUILDING EXTRACTION FROM PHOTOGRAMMETRIC POINT CLOUDS

Point clouds produced by photogrammetric methods are utilized to demonstrate the characteristics of the earth, by involving the color and 3-dimensional position information of the objects. However, 3D digitization is required to determine the land use in the point clouds. Since this process is time consuming and hardware problems are encountered depending on the size of the target region, automatic extraction of target classes is important in terms of workforce and documentation. Machine learning algorithms are capable to extract objects in the photogrammetric point clouds as well. Within the scope of this study, the building extraction performance of the Random Forest (RF) classifier were examined in an open-source urban level point cloud dataset, and the most informative parameters for building extraction were determined. As a result of the test process, 0.816 Accuracy, 0.7916 Sensitivity, 0.9021 Specificity and 0.8702 F1-Score were obtained.

Keywords: Point Cloud, Machine Learning, Classification, Building Extraction

1. GİRİŞ

İnsansız Hava Araçları (İHA) görüntüleri, günümüzde 3-boyutlu modelleme çalışmalarında aktif olarak kullanılmaktadır. Kaydedilen görüntülerdeki her bir piksel, eşlenik noktalar ve konum bilgileri kullanılarak 3-boyutlu konumlandırılma işlemi sonucunda objeleri nokta kümesi şeklinde göstererek nokta bulutlarını oluşturmaktadır. Üretilen nokta bulutlarından, hedef arazi sınıflarının otomatik, hızlı ve doğru tespiti; akıllı şehirler ve coğrafi bilgi sistemleri' ne yönelik altyapıların oluşturulmasında önem arz etmektedir. Son yıllarda gelişen makine öğrenmesi yöntemleri; sınıflandırma, tespit ve tanıma problemlerinin çözülmesinde kullanılmaktadır.

Bu çalışmada, İHA görüntüleri ile üretilen açık kaynaklı bir veri setine ait iki farklı bölgedeki nokta bulutu verisinden üretilen parametreler kullanılarak, binaların 3-boyutlu otomatik çıkarımı için karar ağacı temelli bir makine öğrenmesi sınıflandırıcısı eğitim ve test işlemine tabi tutulmuştur.

2. UYGULAMA

SensatUrban (Hu vd., 2021) veri setine ait iki farklı bölgedeki nokta bulutu verisinden üretilen geometrik parametreler; binaların otomatik çıkarımı için Rasgele Orman (RO) (Breiman, 2001) sınıflandırıcısında eğitim ve test işlemine dahil tutulmuş olup, RO sınıflandırıcısının bina çıkarımındaki performansı ve bina çıkarımında etkili olan parametreleri incelenmiştir. Doğruluk değerlendirmesi için karşılaştırma matrisi elemanları ve bu elemanlardan türetilen metriklerden faydalanılmıştır.

2.1 Veri Seti ve Girdi Parametrelerin Üretilmesi


RO sınıflandırıcısının eğitimi için kullanılan veri seti, İngiltere' de Cambridge ve Birmingham bölgelerinde gerçekleştirilen İHA uçuşları sonucunda elde edilen görüntülerden üretilen nokta bulutundaki arazi sınıflarının etiketlenmesiyle oluşturulmuş olan SensatUrban (Hu vd., 2021) veri setidir. Eğitim ve test için kullanılan nokta

bulutlarındaki her bir noktaya ait 0.5 m, 1 m, 1.5 m ve 2 m yarıçaplı geometrik parametreler (Weinmann vd., 2015) Cloud Compare (Girardeau-Montaut, 2016) yazılımında üretilmiştir (**Çizelge 1**).

Çizelge 1. 0.5 m, 1 m, 1.5 m ve 2 m için üretilen geometrik parametreler (Weinmann vd., 2015)

Parametre İsmi
Pürüzlülük (Roughness)
Doğrusallık (Linearity)
Düzlemsellik (Planarity)
Ortalama Eğrisellik (Mean Curvature)
Dikeylik (Verticality)
Küresellik (Sphericity)
Düzlemsellik (Planarity)
Gauss Eğriliği (Gaussian Curvature)
Birincil, İkincil ve Üçüncül Eigen Değerleri ile Eigen Toplamları (1st, 2nd and 3rd Eigen Values and Sum of Eigen Values)
Birincil Moment (1st Order Moment)
Anisotropy (Anisotropy)

Veri setinin boyutundan ve üretilen parametrelerin bellekteki yerinin fazla olmasından dolayı bu veri setinden bir nokta bulutu (Birmingham_0) eğitim, bir nokta bulutu (Birmingham_7) ise test amaçlı seçilmiştir (**Şekil 1**). Eğitim için kullanılan nokta bulutunda 22.017.383 noktanın 9.645.727 adedi bina, test için seçilen nokta bulutunda ise 19.843.369 noktanın 7.179.961 adedi bina sınıfındadır.



Şekil 1. Eğitim ve test için kullanılan nokta bulutları (a, b) ve bu nokta bulutlarındaki bina sınıflarına ait etiketler (c, d).

2.2. Rasgele Orman Sınıflandırıcısı

Breiman (2001) tarafından geliştirilen Rasgele Orman (RO) algoritması, sınıflandırma ve regresyon problemlerinin çözümünde sıklıkla kullanılan bir denetimli makine öğrenmesi yöntemidir. Bu algoritma, girdi veri setindeki farklı örnekleri kullanarak oluşturduğu karar ağaçlarının sonuçlarını oylama tekniğiyle birleştirilerek girdi verinin sınıf sonucunu belirlemektedir. Algoritma; oluşturulacak karar ağacı sayısı, bir düğümde dikkate alınabilecek maksimum öznelilik sayısını ve bir düğümün en az parçaya bölünebileceğini belirten yaprak sayısını girdi parametresi olarak dahil etmektedir. RO algoritması, Torbalama (Bagging) ve Performans Yükseltme (Boosting) olmak üzere iki ana aşamadan oluşmaktadır. Torbalama aşamasında veri setinden rasgele örnekler alınarak oluşturulan karar ağaçlarında sınıf tahmini oy çokluğu prensibiyle belirlenmektedir. Performans yükseltme aşamasında ise sıralı modeller oluşturularak en yüksek sınıflandırma doğruluğuna ulaşan ağaç seçilir. RO algoritmasında, bütün girdi öznelilikler her ağacın sınıflandırılmasında kullanılmadığından dolayı, paralel hesaplama yeteneği sayesinde hızlı ve veri setinin boyutundan bağımsız şekilde sınıflandırma yapılabilir. Çalışma kapsamında bir düğümdeki maksimum değişken sayısı 6, geliştirilecek olan ağaç sayısı ise 200 olarak seçilmiştir. Eğitim ve test işlemleri Python (3.8) programlama dilinde Scikit-Learn (Buitinck vd., 2013) kütüphanesi kullanılarak gerçekleştirilmiştir.

2.3 Doğruluk Değerlendirmesi

RO sınıflandırıcısında eğitim işlemi gerçekleştirildikten sonra eğitilen modelin test verisindeki performansı incelenmiştir. Doğruluk değerlendirmesinin yapılabilmesi için **Çizelge 2'** de temsil edilen karşılaştırma matrisi birimleri kullanılarak Eşitlik (1), (2), (3) ve (4)' deki Doğruluk, Duyarlılık, Özgüllük ve F1-Skor metrikleri hesaplanmıştır.

Çizelge 2. Karşılaştırma matrisi birimleri (DP: Doğru Pozitif, YP: Yanlış Pozitif, YN: Yanlış Negatif ve DN: Doğru Negatif)

Tahmin	Referans		
		Pozitif	Negatif
	Pozitif Negatif	DP YN	YP DN

$$(DP + DN)/(DP + YP + YN + DN) \quad (1)$$

$$DP/(DP + YN) \quad (2)$$

$$YP/(YP + DN) \quad (3)$$


$$2 * DP/(2 * DP + YP + YN) \quad (4)$$

3. SONUÇLAR VE DEĞERLENDİRME


RO sınıflandırıcısının test veri setinde elde ettiği performans (**Çizelge 3**), 0.816 Doğruluk 0.7916 Bütünlük, 0.9021 Kalite ve 0.8702 F1-Skor olarak gözlemlenmiştir. **Şekil 2'** de RO sınıflandırma sonucuna etki eden en etkili 10 parametre ve test veri setinin tamamındaki sonuçlar, **Şekil 3'** de ise test verisindeki alt bölgelere dair örnek sonuçlar gösterilmektedir. Yükseklik bilgisinin ve Dikeylik parametresinin 0.5 m, 1 m, 1.5 m ve 2 m yarıçapında en etkili parametreler olduğundan dolayı noktalara ait renk bilgilerinden sonra en önemli geometrik parametrelerin ise 2 m' ye ait Üçüncül Eigen Değeri' nin ve 1 m' ye ait Anistropi parametrelerinin olduğu gözlemlenmiştir.

Çizelge 3. RO sınıflandırıcısının test veri setindeki karşılaştırma matrisi ve bu matrsten üretilen doğruluk metrikleri

	Bina-Olmayan	Bina	Doğruluk	Bütünlük	Kalite	F1-Skor
Bina-Olmayan	12234074	429334	0.816	0.7916	0.9021	0.8702
Bina	3221626	3958335				




(a)



(b)

Şekil 2. RO sınıflandırıcısına göre elde edilen en etkili parametreler (a) ve test veri setindeki ROS' a ait bina çıkarımı sonucu (b)

Şekil 1' deki test verisine ait referans etiketler ve **Şekil 2** karşılaştırıldığında; **Çizelge 3'** deki sonuçlara dayanarak, RO sınıflandırıcısının otomatik bina çıkarımında kullanılabilecek sonuçlar verdiği gözlemlenmektedir. Ancak **Şekil 3** incelendiğinde, RO sınıflandırıcısının eğimli çatıya sahip binalarda hatalı, düz çatılarda ise başarılı sonuçlar elde ettiği sonucuna varılmaktadır.



Şekil 3. Test verisi (a) , referans etiket (b) ve RO sınıflandırma sonucu (c)

RO sınıflandırıcısının İHA görüntülerinden üretilen nokta bulutlarından otomatik bina çıkarımında kullanılabileceği görülmüştür. Eğimli çatıların otomatik tespit edilebilmesi için 0.1 – 0.5 m aralığındaki geometrik parametrelerin üretilerek sınıflandırma performansının yükseltilmesi düşünülmektedir. Bir sonraki çalışmalar; son yıllarda gelişmekte olan gradyan artırımı temelli makine öğrenmesi sınıflandırıcılarının eğitim/teste dahil edilmesi ve kullanılan veri setlerindeki bütün eğitim parçalarının kullanılarak veri çeşitliliğinin artırılmasıyla iyileştirme sağlanması şeklinde planlanmaktadır.

KAYNAKLAR

Breiman, L., 2001. Random forests. *Machine learning*, 45(1), pp.5-32.

Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J. and Layton, R., 2013. API design for machine learning software: experiences from the scikit-learn project. *arXiv preprint arXiv:1309.0238*.

Girardeau-Montaut, D., 2016. CloudCompare. *France: EDF R&D Telecom ParisTech*, 11.

Hu, Q., Yang, B., Khalid, S., Xiao, W., Trigoni, N. and Markham, A., 2021. Towards semantic segmentation of urban-scale 3D point clouds: A dataset, benchmarks and challenges. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 4977-4987).

Weinmann, M., Jutzi, B., Hinz, S. and Mallet, C., 2015. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, pp.286-304.