Landsat-8 verilerinden bina yoğunluk analizi haritalarının oluşturulmasında makine öğrenmesi algoritmalarının kullanımı: Adana şehri örneği

The forming of building density analysis maps from the Landsat-8 data with the use of machine learning algorithms: a case study of Adana city

Efdal KAYA¹ , Fatih ADIGÜZEL² , Mehmet ÇETİN³ , Tuğrul AVCI⁴

¹İskendrun Teknik Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, İskenderun, Türkiye

²Nevşehir Hacı Bektaş Veli Üniversitesi, Coğrafya Bölümü, Nevşehir, Türkiye

³Kastamonu Üniversitesi, Peyzaj Mimarlığı Bölümü, Kastamonu, Türkiye

⁴Kahramanmaraş Sütçü İmam Üniversitesi, Sosyal Bilimler Enstitüsü Coğrafya Anabilimdalı, Kahramanmaraş, Türkiye

ORCID: E.K. 0000-0002-5553-0143; F.A. 0000-0002-5978-2495; M.Ç. 0000-0002-8992-0289; T.A. 0000-0003-2395-8134

ÖZ

Uydu teknolojilerindeki gelişimin son yıllarda hızlanması ile birlikte uzaktan algılama teknolojilerinde önemli bir gelişim olmuştur. Özellikle son yıllarda yüksek çözünürlükte mekânsal ve spektral bilgi üreten ve bu bilgiyi topluma sunan yüksek çözünürlüklü uyduların gelişmesi mekânsal bilgi üretiminde çok büyük kolaylık sağlamaktadır. Uydu görüntülerinin fiyatlarının düşmesi ve topluma sunulması da birçok uygulamanın yapılmasını kolaylaştırmıştır. Bu çalışma ile Landsat-8 OLI verisi kullanılarak bina yoğunluk haritası çıkarılmıştır. Landsat verileri indirildikten sonra öncelikle radyometrik ve geometrik düzeltme işlemine tutulmuştur. Daha sonra çalışma alanına göre kesilerek makine öğrenmesi algoritmalarından olan destek vektör makineleri (DVM) ile sınıflandırılmıştır. Sınıflandırma işlemi sonrasında bina verileri polygon veri yapısında kaydedilmiştir. Polygon verisi içerisinde nokta atılmıştır. Atılan bu nokta verileri kullanılarak bina yoğunluk haritası oluşturulmuştur.

Anahtar Kelimeler: Uzaktan Algılama, Bina Yoğunluk Haritası, R Programlama, Landsat-8.

ABSTRACT

In recent years, the increasing development of satellite technologies has played an important role in the development of remote sensing technologies. In particular, the development of high-resolution satellites that produce high-resolution spatial images and present spectral information to the public has provided significant convenience for obtaining spatial information. The decreasing prices of the satellite images and their presentation to the community have facilitated the implementation of many applications. In this study, a density map is created using Landsat-8 OLI data. To determine the usability of the density map, the data obtained from Landsat satellites are offered to users for free. The downloaded Landsat data were initially subjected to radiometric and geometric corrections. Then, the image is cut into different scenes based on the study area and data are classified using support vector machine, which is a machine learning algorithm. After classification, the building data were recorded in a polygon data structure. Each polygon in the structure was filled with dots and building density map was created using these point data.

Keywords: Remote Sensing, Building Density Map, R Programming, Landsat-8.

Başvuru/Submitted: 30.03.2019 **Kabul/Accepted:** 29.05.2019

Sorumlu Yazar/ Corresponding author: Efdal KAYA / efdal.kaya@iste.edu.tr

Atıf/Citation: Kaya, E., Adiguzel F., Cetin M., Avci T. (2019). Landsat-8 verilerinden bina yoğunluk analizi haritalarının oluşturulmasında makine öğrenmesi algoritmalarının kullanımı: Adana şehri örneği. B. Gonencgil, T. A. Ertek, I. Akova ve E. Elbasi (Ed.), 1st Istanbul International Geography Congress Proceedings Book (s. 300-304) içinde. İstanbul, Türkiye: Istanbul University Press. <https://doi.org/10.26650/PB/PS12.2019.002.029>

1. GİRİŞ

Uydu görüntüleri ormancılıktan jeodeziye, meteorolojiden askeri uygulamalara kadar birçok alanda kullanılmaktadır. Uydu görüntülerinin insan gözünün algılayamadığı bitki hastalıkları, klorofil miktarı, su kalitesi ve su kirliliği gibi özellikleri ayırt edebilmesi birçok kolaylığı ve analiz kolaylığını da beraberinde getirmiştir. Sınıflandırma görüntü yorumlama teknikleri kullanılarak görüntüdeki homojen piksel gruplarının ilgilenilen yeryüzü özelliklerine ve yeryüzü kullanım özelliklerine ayrılması şeklinde tanımlanabilir (Chandra ve Ghosh, 2007; Duro vd., 2012; Melgani ve Bruzzone, 2004). Dijital görüntü sınıflandırmada ise, kullanıcı görüntüdeki dijital sayılarla gösterilen spektral bilgiyi kullanarak çeşitli bantlar üzerinde spektral özelliklere göre pikselleri sınıflandırır. Bu tip sınıflandırmaya spektral doku tanımlama da denebilir. Burada amaç görüntüdeki tüm pikselleri çeşitli sınıflara ya da temalara atamaktır. Sınıflandırma sonucunda oluşan haritada her piksel kendine mahsus bir özelliğe atanmış bir şekilde orijinal görüntünün tematik haritası elde edilmiş olur (Kalkan ve Maktav, 2010).

2. ÇALIŞMA ALANI

Türkiye'nin güneyinde yer alan Adana; doğuda Osmaniye, Kahramanmaraş, Gaziantep, batıda İçel, kuzeybatıda Niğde, güneydoğuda Hatay gibi illerle ve güneyde Akdeniz'e olan sınırları ile Akdeniz Bölgesinin Çukurova Bölgesinde bulunmaktadır. Tüm ova Adana Ovası olarak adlandırılır fakat güney bölümünde kalan parçaya Çukurova ve kuzey tarafta kalan bölüm ise Yukarıova veya Anavarza denir. Şehir Seyhan Nehrinin iki yakasında 35°-38° kuzey enlemi ve 34°-36° doğu boylamında yer almaktadır. Yüzölçümü 14.030 km²'dir (Url-1).

Şekil 1: Çalışma alanı

3. UYGULAMA

Bu çalışmada öncelikle Landsat-8 verileri Earth Explorer adresinden indirilmiştir. Landsat-8 verilerine ait özellikler Tablo 1'de gösterilmiştir.

Tablo 1. Landsat-8 Uydu görüntüsünün özellikleri

Şerit Genişliği (km)	185
Radyometrik Çözünürlük (bit)	8
	TIR - 12
Yersel Çözünürlük (m)	PAN - 15
(PAN = siyah beyaz)	OLI - 30
	TIR - 100

Landsat-8 verileri indirildikten sonra ön işlemler yapılmıştır. Ön işleme aşamasında ilk olarak radyometrik düzeltme yapılmıştır. Daha sonra sensörden kaynaklanan hatalar giderilmiştir. Daha sonra çevresel etkilerden kaynaklanan hatalar düzeltilmiştir.

3.1 R PROGRAMLAMA

R Programlama dili açık kaynak kodlu bir programlama dilidir. R programlama dili Ross Ihaka ve Robert Gentleman tarafından Yeni Zelanda da geliştirilmeye başlanmıştır. Bugün birçok kullanıcı tarafından kütüphaneler geliştirilmektedir. Mekansal veri analiz, veri görselleştirme, veri madenciliği, makine öğrenmesi, veri bilimi gibi birçok alanda yaygın olarak kullanılmaktadır.

Çalışma kapsamında yazılan kodlar github sayfasından paylaşılmıştır (Url-2).

3.2 DESTEK VEKTÖR MAKİNELERİ

“Destek Vektör Makinesi” (SVM), sınıflandırma veya regresyon problemleri için kullanılabilen denetimli bir makine öğrenmesi algoritmasıdır. Bununla birlikte, çoğunlukla sınıflandırma problemlerinde kullanılır. Bu algoritmada, her bir veri maddesini belirli bir koordinatın değeri olan her özelliğin değeri ile birlikte n-boyutlu boşluğa (burada n sahip olduğunuz özelliklerin sayısı) bir nokta olarak çizilir. Ardından, iki sınıftan oldukça iyi ayrım yapan hiper-düzlemi bularak sınıflandırma gerçekleştirilir.

Şekil 2: DVM sınıflandırma yönteminde sınıf ayrımı

3.3 BİNA YOĞUNLUK HARİTASININ OLUŞTURULMASI

İlk olarak Landsat-8 uydu görüntüsü R programlama dilinde kodlanarak sınıflandırılmıştır (Şekil 3).

Şekil 3: Sınıflandırılan Landsat-8 uydu görüntüsü

Sınıflandırılan Landsat-8 uydu görüntüsü üzerinden bina verileri çekilerek bina yoğunluk haritası oluşturulmuştur (Kaya vd., 2019;) (Şekil 4).

Şekil 4: Bina yoğunluk haritası

4. SONUÇ ve ÖNERİLER

Kentsel alanlarda binaların hızlı bir şekilde artması ile bina yoğunluk haritalarının çıkarılması önemli hale gelmiştir. Bina yoğunluk haritaları kent içi biyoklimatik konfor alanlarının belirlenmesi için önemli temel altlık haritalardandır. Yapılan bina yoğunluk haritaları imar planlarının oluşturulması sırasında dikkate alınacak önemli altlık haritalardır.

Uydu görüntülerindeki mekansal çözünürlüklerinin 30 cm'nin altına düşmesi ile birlikte detaylı veri üretimi sağlanmaktadır. Landsat verilerinin mekansal çözünürlüğü pankromatik bant için 15 metre, diğer multispaktral bantlar için 30 metre ve termal bantlar için 60 metredir. Yapılan çalışma ile Landsat verisinin multispektral bantlarının çözünürlüğü 15 metre düşürülmüştür. Makine öğrenmesi algoritmalarından olan DVM ile veri sınıflandırılmıştır. Sınıflandırma neticesinde mekansal çözünürlüğün düşük olması nedeniyle binaların detaylı şekilde çıkarımı tam olarak gerçekleştirilememiştir. Binalar bütün halde tek bir bina alanı birçok alanda çıkmıştır. Bu tür bina şekli de tam olarak çalışma alanını yansıtmamaktadır. Otomatik bina yoğunluğunun belirlenmesi çalışmalarında en önemli girdi binaların belirlenmesi olduğu için binaların en hassas biçimde çıkarılması gerekmektedir. Yüksek hassasiyette çıkarılan binaların ortasına atılan noktalar yardımı ile de hassas bina yoğunluk haritası oluşturulmalıdır.

KAYNAKLAR

- Chandra, A. M., Ghosh, S. K. (2007). Remote Sensing and Geographical Information System, Alpha Science International, Oxford U.K. ss 16-24, 97-114.
- Cheng, G., Han, J., (2016). A survey on object detection in optical remote sensing images. ISPRS J. Photogramm. Remote Sens. 2016, 117, 11–28.
- Duro, D.C., Franklin, S.E., Dubé, M.G., (2012). Multi-scale object-based image analysis and feature selection of multi-sensor earth observation imagery using random forests. Int. J. Re-mote Sens. 2012, 33, 4502–4526.
- Kalkan K., Maktav D. (2010). Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS Örneği), III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 11 – 13 Ekim 2010, Gebze – KOCAELİ
- Kaya E., Agca M., Adiguzel F., Cetin M., (2019). Spatial Data Analysis with R Programming for Environment, Human And Ecological Risk Assessment 2019, VOL. 25, NO. 6, 1521–1530, <https://doi.org/10.1080/10807039.2018.1470896>
- Melgani, F., Bruzzone, L., (2004). Classification of hyperspectral remote sensing images with support vector machines. IEEE Trans. Geosci. Remote Sens. 2004, 42, 1778–1790.
- URL -1: <http://www.adana.gov.tr/cografya> Alındığı tarih: 15.08.2019
- URL-2: <https://github.com/efdalkaya> Alındığı tarih: 15.08.2019