




## International Geoinformatics Student Symposium

<https://igss.mersin.edu.tr>



### Mersin İli Arazi Kullanımı ve Arazi Örtüsü Çalışması için Makine Öğrenmesi ile Görüntü Sınıflandırması

Şafak Bozduman \*<sup>1</sup> 

<sup>1</sup>Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Mersin, Türkiye

#### Anahtar Kelimeler

Uzaktan Algılama  
Sınıflandırma  
Makine Öğrenmesi  
GEE  
Arazi Örtüsü/Kullanımı

#### ÖZ

Arazi örtüsü kullanım verisi tarım politikalarının, kentsel büyüme ve kentsel planlamanın sürdürülebilir yönetiminde temel olarak kullanılabilir. Son yıllarda araziler hakkında hızlı ve güncel veriye ulaşabilmek için sıklıkla uzaktan algılama yöntemleri kullanılmaktadır. Bu yöntemlere dünyamızda yaşanan problemleri gün yüzüne çıkartmak ve bu problemler için daha önce üretilmiş olan çözüm yöntemlerini iyileştirmek amacıyla başvurulmaktadır. Arazi kullanımı ve arazi örtüsü çalışmaları için arazi örtüsü kullanım haritalarının üretilmesi gerekmektedir. Bu bağlamda yapılan literatür taramaları sonucunda; uydu görüntülerinin ham hali üzerinden yorum yapmak oldukça zor olduğu için çalışma sahasının büyüklüğüne uygun olabilecek çözünürlüğe sahip uydu veya uydularla çalışılıp, yine çalışmaya uygun sınıflandırma yöntemi ve ona uygun indeks seçimiyle beraber yüksek doğrulukta haritalar oluşturmanın mümkün olduğu görülmektedir. Gelişen teknolojiler ile beraber, bulut bilişim platformu kullanılarak platform üzerinden erişilebilen milyonlarca uydu görüntüsü veri setinden çalışmaya uygun olan uydu görüntüleri seçilir ve görüntülerin ön işleme adımları da bulut ortamında sağlanır. Bu sayede, görüntülerin işlenmesi ve saklanması olması gerekenden daha az maliyet gerektirecektir. Uydu görüntülerinin sınıflandırılması çalışmalarında kontrollü ve kontrolsüz makine öğrenmesi algoritmaları kullanılmış ve farklı indekslerle ortaya koyacakları performansları karşılaştırılarak yorum yapılmıştır.

### Image Classification with Machine Learning for Land Use and Land Cover Study in Mersin Province

#### Keywords

Remote sensing  
Classification  
Machine Learning  
Land Use/Land Cover

#### ABSTRACT

Land cover use data can be used as a basis for sustainable management of agricultural policies, urban growth, and urban planning. In recent years, remote sensing methods are frequently used to reach fast and up-to-date data about the lands. These methods are used to bring the problems in our world to light and improve the solution methods produced for these problems before. Land cover use maps need to be produced for land use and land cover studies. As a result of the literature review made in this context; Since it is very difficult to comment on the raw form of satellite images, it is possible to work with satellites or satellites with a resolution that can be suitable for the size of the study area, and to create high-accuracy maps with the appropriate classification method and the appropriate index selection. Along with the developing technologies, suitable satellite images are selected from the millions of satellite image data sets that can be accessed on the platform using the cloud computing platform, and the preprocessing steps of the images are provided in the cloud environment. In this way, processing and storing images will require less cost than it should be. Controlled and uncontrolled machine learning algorithms were used in the classification of satellite images and their performances were compared with different indexes and comments were made.

*Kaynak Göster (APA);*

\*Sorumlu Yazar

<sup>\*</sup>(safak.bozduman@gmail.com) ORCID ID 0000-0003-0359-9090

Bozduman Ş (2021). Başlık İli Arazi Kullanımı ve Arazi Örtüsü Çalışması için Makine Öğrenmesi ile Görüntü Sınıflandırması. *Intercontinental Geoinformation Days (IGD)*, 1-3, Mersin, Turkey

## 1. GİRİŞ

Kentsel alanların fiziksel ayak izi genişledikçe, arazi örtüsü ve arazi kullanımında (AÖAK) radikal değişimler meydana gelmektedir. Dünya genelinde hızlıca artan kentleşme oranı, verimli arazi kullanımının düşmesini, tarımsal arazilerin tarım faaliyetleri dışına çıkarılmasını ve doğal yaşam alanlarının tahribatını da beraberinde getirmiştir. Kentsel alanların değişiminin izlenmesine ve gelecekte kentsel alanların kırsal alanlara doğru büyümesinin hangi yönlerde ne ölçüde olacağını kestirilmesine (simüle edilmesine) ilişkin çalışmalar yerli ve yabancı literatürde oldukça yaygın olduğu görülmektedir.

Sınıflandırma işlemlerinin doğruluğunu arttırmak için, çalışmalara katkı vermesi düşünülen birçok metod denenmiştir. Bunlar; uydu görüntüleri, uyduların bant özellikleri, sınıflandırma doğruluğunu arttırdığı düşünülen indeksler, matematiksel algoritmalara, sınıflandırma verileri vb. etkenlerdir.

Sınıflandırma işlemlerinde başlıca iki yaklaşım vardır. Bunlar; kontrollü sınıflandırma ve kontrolsüz sınıflandırmadır. Kontrolsüz sınıflandırma; kullanıcı etkisi olmaksızın, piksellerin benzer özellik gösteren görüntü üzerindeki objelere atanması prensibiyle çalışmaktadır.

Kontrollü sınıflandırma ise; yeryüzünde konumu ve özellikleri bilinen objelerin, sınıflandırma sonrasında test verisi olarak işleme sokulması prensibine dayanmaktadır.

Kalem (2014), Göktürk-2, Spot-5 ve Landsat-8 uydu görüntülerini kullanarak sınıflandırma işlemi yapmıştır. İşlemler sonrasında Landsat-8 uydu görüntüsüyle yapılan sınıflandırmanın doğruluk değerinin daha yüksek olduğu tespit edilmiştir. Landsat-8 uydusunun yüksek doğrulukta sonuç vermesi, daha çok bant bilgisine sahip olduğunda ilişkilendirilmiştir. Abdikan vd. (2018), çalışmalarında Sentinel-2A uydu görüntüsü üzerinden sınıflandırma işlemleri yapılmıştır. İşlemler sırasında maksimum olabilirlik (MO), DVM ve YSA metotları denenmiştir. Bu işlemler kıyaslandığında ise en iyi sonucu YSA ağları vermiştir.

## 2. ARAZİ KULLANIM ve ARAZİ ÖRTÜSÜ SINIFLANDIRMA YÖNTEMLERİ

Uzaktan algılama görüntülerinin ham hali üzerinde yorum yapmak oldukça zordur. Fakat günümüzde uydu görüntüsü sınıflandırma işlemi ile hızlı ve doğru bir şekilde arazi kullanımı ve arazi örtüsü hakkında bilgi edinilebilmektedir.

Sınıflandırma işlemi 2'ye ayrılmaktadır. Bunlardan biri nesne tabanlı sınıflandırma diğeri ise piksel tabanlı sınıflandırmadır. Piksel tabanlı sınıflandırma 2'ye ayrılmaktadır. Bunlar kontrollü ve kontrolsüz sınıflandırmadır.

Arazi-kullanımı/örtüsü sınıflandırmasında kullanılabilen, kontrollü sınıflandırmada birçok sınıflandırma teknikleri vardır. Makine öğrenme algoritmaları parametrik olmayan kontrollü sınıflandırma teknikleridir ve göreceli olarak makaleler yayımlanır.

### 2.1. Destek vektör makineleri (DVM)

Uzaktan algılama çalışmalarında sıkça kullanılan yöntemlerden biridir. DVM yöntemi kontrollü sınıflandırma yöntemleri arasında yer almaktadır (Melgani, 2004). DVM yöntemi, 2 ayrı sınıfa ait verileri birbirinden ayırmak için uygun değer hiperdüzlem belirlemektedir. Hiperdüzlem olarak bahsedilen bu düzlemin, sınıflar arası sınırının maksimum olması istenir. Yani sınıflara ilişkin en uygun düzlemi bulmalı ve hepsini kapsamalıdır. Bu sınıflandırma yöntemi ilk gün yüzüne çıktığında birbirinden doğrusal olarak ayrılabilen 2 ayrı sınıf üzerinde ayırıştırma yapmaya yönelik çalışmalarda kullanılmıştır. Daha sonradan 2'den fazla sınıfta içinde bulunduğu ve birbirinde doğrusal olarak ayrılamayan sınıflandırma işlemlerinde de kullanılmaya başlanmıştır (Vapnik, 1995).

### 2.2. Karar Ağacı

Tümevarımsal öğrenme algoritmalarından biridir. Bu algoritma eğitim verilerini / örneklerini kullanarak sınıflandırma ağacı oluşturur. KA'nın çalışma prensibi "böl ve yönet" stratejisine dayanır. Bu algoritma doğası gereği parametrik olmayan bir dağılımdır, dolayısıyla verilerin dağılımından bağımsızdır. Bu nedenle sınıflandırma işlemine sınıflandırılmamış veriyi dâhil etmek için uygundur. Böylelikle sınıf ayrışmasında iyileşme sağlanabilir. Anlamsız Sınıflama problemlerini ikiden fazla sınıfla destekler ve regresyon problemlerini ele almak için modifiye edilebilir. Karar ağacı yaklaşımı, arazi örtüsünü sınıflandırma problemleri için önemli avantajlara sahiptir, çünkü özellikler ile sınıflar arasındaki doğrusal olmayan ilişkilerin üstesinden gelebilme yeteneğinden dolayı sınıflandırma doğruluğunu büyük ölçüde geliştirir (Paul & Mahesh, 2001).

### 2.3. Rasgele orman (RO)

Temel sınıf olarak karar ağacını kullanan en tanınmış topluluk algoritmalarından biridir. Rastgele bir orman yapısı, üç ana aşamadan oluşan bir topluluk inşa etme sürecine uygundur.

1. Topluluk çeşitliliğini kazanmak-RO algoritmasında örnekleme yöntemi kullanılarak bir eğitim veri seti oluşturulur.

2. Temel klasörler oluşturma - RO, temel klasörler oluşturmak için önceki adımda oluşturulan farklı eğitim setlerinde rastgele bir ağaç olan aynı indükleyiciyi kullanır. Ayrıntılı olarak, her düğümde, küçük bir girdi öznitelik grubu rastgele seçilir. Grubun boyutu kullanıcılar tarafından önceden belirlenebilir.

3. Temel sınıfları birleştirmek - RO algoritmasında çoğunluk oylama yöntemi kullanılmaktadır.

### 2.4. K-ortalama Algoritması

Parametrik olmayan ve denetimsiz makine öğrenmesi algoritmalarından biri olan K-ortalama algoritması, sayısal görüntü işlemede kullanılan ve veri

setini türdeş gruplara ayıran, yinelemeli kümelemeye dayanan bir sınıflandırma yöntemidir.

## 2.5. Yapay Sinir Ağları

Bir diğer parametrik olmayan denetimsiz makine öğrenmesi yaklaşımı da yapay sinir ağlarıdır (YSA). YSA, karmaşık davranışların ve örüntülerin nicel olarak ölçülmesini ve modellenmesini sağlayan bir teknik olup, veri seti ile ilgili önceden bilinen bir dağılım bilgisine gerek duymaz. Lineer olmayan veri kümelerine ve farklı veri tiplerine esnek bir yöntemdir.

## 3. GOOGLE EARTH ENJİNE (GEE)

Google Earth Engine (GEE) kullanıcının masaüstünde büyük hacimli verileri indirip işlemeden, dünya genelinde herhangi bir kullanıcı tarafından belirlenen bölge için verileri hızlı bir şekilde analiz etme ve görselleştirme imkanı sunan bir arayüzdür (Sazib vd., 2018). GEE aracı verilerin görselleştirilmesi ve yorumlanması için kolaylık sağlar. GEE herhangi bir ek yazılım kurulumu gerektirmez, internete bağlı herhangi bir bilgisayarda kullanıcının mevcut kodlara ve verilere erişimini sağlamaya yardımcı olur. (Sazib vd., 2018). Shelestov vd.'nin çalışmalarında Google Earth Engine'in (GEE) bulut platformu üzerinden uzaktan algılama ürünlerine erişimi sağlamada çok iyi bir performans sağladığını, ancak sinir ağları topluluğuna dayalı yaklaşımımızın GEE'de bulunan SVM, karar ağacı ve rastgele orman sınıflandırıcılarını geride bırakarak daha iyi performans gösterdiğini bulmuşlardır. GEE platformu, örneğin sınıflandırma amaçları ve büyük bölgeler için kırpma haritalama için kullanılabilir büyük hacimli uzaktan algılama görüntülerini işlemede güçlü yetenekler sunar.

## 4. TARTIŞMA ve SONUÇ

Uzaktan algılama teknolojisi, uzay teknolojilerin gelişmesi ile birlikte hayatımıza girmiştir. Dünyanın hemen her yerinde, birçok çalışma için kullanılmaktadır. Gelişen teknoloji ile birlikte uzaktan algılama teknolojilerin yetenekleri gelişmekte ve buna bağlı olarak çalışmalarda kullanım oranı ve doğru sonuç verme oranları artmaktadır. Deniz kirliliği tespiti, orman tahribatı tespiti, kentleşme yoğunluğu, tarım alanları takibi gibi birçok alanda kullanılmaktadır.

Şeker (2021) tez çalışmasında farklı iki uydu tipi kullanılmış ve makina öğrenmesi algoritmaları kıyaslaması yapılmıştır. Çalışmanın sonucunda, her iki uydu görüntüsü için de Destek Vektör Makineleri ve Sinir Ağları sınıflandırmaları birbirlerine oldukça yakın genel doğruluk ve kappa değerleri elde edildiği sonucuna

varmıştır. Bunun yanı sıra Dizdaroğlu (2019), çalışmasında elde edilen sonuçlara göre, KA algoritmasının sınıflandırma doğruluğu RO ve DVM algoritmalarına göre daha düşüktür. Bu fark yaklaşık %4 civarında olmuştur.

## 5. KAYNAKÇA

Abdikan S, Narin Ö & Delen A (2018). SENTİNEL-2A Verisi Kullanarak Tarımsal Ürün Deseninin Belirlenmesi. *Uzaktan Algılama-CBS Sempozyumu*, 18-21 Eylül 2018, Eskişehir.

Dizdaroğlu T (2019). Sentinel-1 ve Sentinel-2 Verilerinden Tarımsal Ürün Sınıflandırması İçin Makine Öğrenme Algoritmalarının Karşılaştırılması. *Yüksek Lisans Tezi*, Zonguldak Bülent Ecevit Üniversitesi, 2019.

Kalem E (2014). Piksel ve Nesne Tabanlı Sınıflandırma Açısından GÖKTÜRK 2 Görüntüsünün Değerlendirilmesi: İstanbul Boğazı Örneği. *Yüksek Lisans Tezi*, Hava Harp Okulu Havacılık ve Uzay Teknolojileri Enstitüsü, Uzay Bilimleri Anabilim Dalı, İstanbul, 91 s.

Melgani F & Bruzzone L (2004). Classification Of Hyperspectral Remote Sensing Images With Support Vector Machines. *IEEE Transactions On Geoscience and Remote Sensing*, 42 (8), 1778-1790.

Paul M M & Mahesh P (2001). Decision Tree Base Classification of Remotely Sensed Data, 22nd Asian Conference on Remote Sensing, Nottingham.

Sazib N, Mladenova I & Bolten J (2018). Leveraging the Google Earth Engine for Drought Assessment Using Global Soil Moisture Data. *Remote Sensing*, 10(8), 1265.

Şeker M (2021). Farklı Sınıflandırma Algoritmaları Kullanarak Sentinel-2 ve Landsat 8 Verileri Sınıflandırılması ve Tematik Doğruluk Değerlendirmesi (Silifke İlçesi Örneği). *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, 2021.

Vapnik V N (1995). The Nature Of Statistical Learning Theory. Springer-Verlag, New York, 138-167.

