



MTA Yerbilimleri ve Madencilik Dergisi

<https://yermad.mta.gov.tr/>



Bursa ili 2001-2022 dönemi arazi örtüsü ve arazi kullanım değişiminin makine öğrenme ve uzaktan algılama yöntemleriyle analizi

Solmaz BABAKAN^{a*} ve Uğur ALGANCİ^b

^aRSW Sürdürülebilirlik ve Bilgi Teknolojileri Danışmanlık, İstanbul, Türkiye.

^bİstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Araştırma Makalesi

Anahtar Kelimeler:

Arazi Örtüsü ve Arazi Kullanımı, Google Earth Engine, Destek Vektör Makineleri, Rastgele Ormanlar, Bursa.

ÖZ

Bu çalışma, Bursa ilinde 2001-2022 döneminde Arazi Örtüsü/Arazi Kullanımı (AÖ/AK) değişimlerini analiz etmeyi amaçlamaktadır. Landsat 5 TM ve Landsat 8 OLI/TIRS görüntüleri kullanılarak yaklaşık on yıllık aralıklarla AÖ/AK haritaları üretilmiş ve Google Earth Engine platformunda Destek Vektör Makineleri (DVM) ve Rastgele Orman (RO) algoritmaları ile sınıflandırılmıştır. Sınıflandırmalar iki yaklaşımla gerçekleştirilmiştir: (i) doğrudan spektral bantlara dayalı ve (ii) NDVI, yerleşim indeksi ve bant oranları gibi türetilmiş indikatör faktör haritalarına dayalı. Altı ana sınıf (su, orman, tarım, çorak alan, kentsel alan ve maden) değerlendirilmiştir. Eğitim verilerinde tüm yıllarda %99'un üzerinde genel doğruluk elde edilmiş, RO algoritması %100'e yakın performans göstermiştir. Test verilerinde spektral bant yaklaşımı 2011 yılı için %86,42-88,49 doğruluk üretirken, indikatör tabanlı yaklaşım aynı yıl %95,97-97,69 aralığında doğruluk sağlamıştır. 2022 yılında en yüksek test doğruluğu RO algoritması ile %98,15 olarak belirlenmiştir. Zamansal analizler, 2001-2022 döneminde çorak alanların azaldığını; tarım, kentsel ve maden alanlarının ise artış eğiliminde olduğunu göstermiştir. Bulgular, türetilmiş spektral göstergelerin sınıflandırma performansını belirgin biçimde artırdığını ortaya koymaktadır.

Gönderim Tarihi: 11.10.2025

Kabul Tarihi: 20.05.2026

Keywords:

Land Use and Land Cover, Google Earth Engine, Support Vector Machines, Random Forest, Bursa.

ABSTRACT

This study investigates Land Cover/Land Use (LC/LU) changes in Bursa between 2001 and 2022. LC/LU maps were produced at approximately ten-year intervals using Landsat 5 TM and Landsat 8 OLI/TIRS imagery and classified on the Google Earth Engine platform using Support Vector Machines (SVM) and Random Forest (RF) algorithms. Two approaches were implemented: (i) direct use of spectral bands and (ii) classification based on derived indicator factor maps, including NDVI, built-up index, and selected band ratios. Six main classes were analyzed: water bodies, forest, agriculture, barren land, urban areas, and mines. Overall accuracies for training data exceeded 99% for all years, with RF reaching nearly 100%. For test datasets, the spectral band approach produced accuracies of 86.42-88.49% in 2011, whereas the indicator-based approach significantly improved performance to 95.97-97.69%. The highest test accuracy (98.15%) was obtained using RF with indicator factors in 2022. Temporal analysis revealed a decrease in barren lands and an increase in agricultural, urban, and mining areas over the study period. The findings demonstrate that integrating derived spectral indicators enhances classification accuracy and supports reliable large-scale LC/LU mapping.

Received Date: 11.10.2025

Accepted Date: 20.05.2026

Atf Bilgisi: Babakan, S., Algancı, U. 2026. Bursa ili 2001-2022 dönemi arazi örtüsü ve arazi kullanım değişiminin makine öğrenme ve uzaktan algılama yöntemleriyle analizi. MTA Yerbilimleri ve Madencilik Dergisi 9, 75-89.

*Başvurulacak yazar: Solmaz BABAKAN, solmaz@resuwo.com

1. Giriş

Mühendislik ve teknoloji tarihinin en önemli dönüm noktalarından biri olarak kabul edilen uzaktan algılama kavramı, yaklaşık elli yıldır bilimsel literatürde yer almaktadır. Uzaktan algılama; nesneler, yüzeyler ya da bölgeler hakkında doğrudan temas olmaksızın, genellikle uçaklar veya uydular aracılığıyla bilgi toplanmasını konu alan bir bilim dalıdır. Birleşmiş Milletler (95. Genel Kurul, 3 Aralık 1986)'e göre, Uzaktan Algılama, “algılanan nesneler tarafından yayılan, yansıtılan veya kırılan elektromanyetik dalganın özelliklerinden yararlanarak, doğal kaynak yönetimi, arazi kullanımı ve çevrenin korunmasının iyileştirilmesi amacıyla dünya yüzeyinin uzaydan algılanması” şeklinde tanımlanmıştır (Yadav vd., 2013).

Uzaktan algılama verilerinin etkin biçimde kullanımı, pek çok farklı disiplinde kendini kanıtlamış olup, yeryüzündeki zamansal değişimlerin izlenmesine de güçlü bir katkı sağlamaktadır. Uzaktan algılama teknolojileri; tarım, jeoloji, ormancılık, hidroloji, okyanus ve kıyı yönetimi, arazi kullanımı, peyzaj ekolojisi, biyoçeşitlilik ve çevre bilimleri gibi alanlarda araştırmacılara gözlem, analiz ve değerlendirme olanağı sunmaktadır. Bu teknolojinin bilimsel çalışmalarda kullanım alanı her geçen yıl daha da artış göstermektedir (Yadav vd., 2013).

Uzaktan algılama yoluyla elde edilen arazi örtüsü verileri; arazi kullanımı haritalarının oluşturulması, çevresel değişkenlerin takibi ve doğal ekosistemleri doğrudan etkileyen arazi örtüsü dinamiklerinin analizinde başarıyla kullanılmaktadır.

Bu çalışmada, uydu görüntülerinden yararlanılarak Bursa ilindeki arazi kullanım sınıflarının belirlenmesi ve zamansal değişimlerinin incelenmesi amaçlanmıştır. Araştırma kapsamında, Bursa ili sınırları içinde Arazi Örtüsü/Alan Kullanımı (AÖ/AK) değişimlerinin ortaya konulması için, bölgedeki kentsel büyümenin öncesi ve sonrası dönemlerinin karşılaştırılması yapılmıştır.

2. Literatür Taraması

Uzaktan algılama teknolojileri, geniş alanlarda zamansal ve mekânsal değişimlerin izlenmesine olanak sağlaması nedeniyle AÖ/AK analizlerinde

yaygın biçimde kullanılmaktadır. Dünya yüzeyindeki hızlı değişimler; kentleşme, madencilik faaliyetleri, tarımsal genişleme ve iklimsel etkiler gibi faktörlerle ivme kazanmakta, bu durum sürdürülebilir arazi yönetimi açısından güvenilir ve çok zamanlı veri ihtiyacını artırmaktadır. Uydu görüntüleri, özellikle Landsat serisi gibi uzun dönemli arşiv sunan sistemler, bu değişimlerin sistematik biçimde analiz edilmesine imkân tanımaktadır.

AÖ/AK değişimlerinin belirlenmesinde çok zamanlı Landsat verilerinin kullanımı literatürde geniş yer bulmaktadır. Örneğin, Bakır vd. (2010), Mısır'da Landsat verileri ile hibrit sınıflandırma ve NDVI tabanlı analizler kullanarak dört ana arazi sınıfında yüksek doğruluklu sonuçlar elde etmişlerdir. Benzer şekilde, Amini vd. (2022), Landsat 5, 7 ve 8 verilerini kullanarak spektral indeksler, Sayısal Yükseklik Modeli (DEM) ve Arazi Yüzey Sıcaklığı (LST) gibi yardımcı değişkenlerin sınıflandırma doğruluğunu artırdığını göstermiştir. Çalışmalar, özellikle veri ön işleme tekniklerinin ve çoklu veri entegrasyonunun sınıflandırma performansına doğrudan katkı sağladığını ortaya koymaktadır.

Spektral bant kombinasyonları ve bant oranlama teknikleri, hem arazi örtüsü ayrımında hem de mineral ve alterasyon alanlarının belirlenmesinde etkili yöntemler olarak öne çıkmaktadır. Rajendran ve Nasir (2013), bant oranları ve Temel Bileşen Analizi (TBA) kullanarak stratiform manganer oluşumlarını başarılı biçimde haritalamışlardır. Benzer biçimde Al-Rawashdeh vd. (2006), Landsat ETM+ ve SAR verilerini birlikte değerlendirerek jeolojik birimlerin ve hidrotermal alterasyon zonlarının ayrımında bant oranı, TBA ve Ton ve Doygunluk (IHS) dönüşüm tekniklerinin etkinliğini göstermiştir. Bu çalışmalar, spektral dönüşümlerin ve veri zenginleştirme yöntemlerinin, doğrudan bant kullanımına kıyasla ayırt ediciliği artırdığını ortaya koymaktadır.

Madencilik ve alterasyon haritalama çalışmalarında da benzer yaklaşımlar uygulanmıştır. Nasir ve Rajendran (2017), ASTER verileri üzerinde bant oranı, doğrusal spektral ayrıştırma ve MTMF yöntemlerini kullanarak ekonomik minerallerin belirlenmesinde uzaktan algılamanın

yüksek potansiyelini vurgulamışlardır. Uysal vd. (2017) ile Büyüksağış ve Gürsoy (2017) ise bant oranlama tekniklerinin belirli mineral türlerinin ayırt edilmesinde etkin sonuçlar verdiğini göstermiştir. Ayrıca, Babakan ve Oskoue (2014), özellik odaklı bileşen analizi ve bant oranlarını yapısal verilerle entegre ederek altın cevherleşme potansiyelinin güvenilir biçimde haritalanabileceğini ortaya koymuştur. Bu bulgular, görüntü iyileştirme tekniklerinin yalnızca jeolojik analizlerde değil, arazi örtüsü ayrımında da potansiyel avantajlar sunduğunu göstermektedir.

Kentleşme ve çevresel değişim bağlamında yapılan çalışmalar da uzaktan algılama temelli analizlerin önemini desteklemektedir. Başaran (2021), Akdeniz Bölgesi'nde orman kayıplarının kentleşme ve iklimsel faktörlerle ilişkisini NDVI ve çeşitli çevresel parametreler üzerinden analiz ederek, çok değişkenli istatistiksel yaklaşımların çevresel değerlendirmelerde etkin olduğunu göstermiştir.

Mevcut literatür genel olarak; (i) çok zamanlı Landsat verilerinin AÖ/AK değişim analizinde güvenilir bir kaynak olduğunu, (ii) bant oranlama ve TBA gibi görüntü zenginleştirme tekniklerinin sınıflandırma performansını artırabildiğini ve (iii) yardımcı çevresel değişkenlerin doğruluğu yükseltebildiğini ortaya koymaktadır. Bununla birlikte, makine öğrenmesi algoritmalarının bulut tabanlı platformlar üzerinde, hem doğrudan spektral bantlar hem de indikatör faktör haritalarıyla karşılaştırmalı biçimde uygulanmasına yönelik çalışmalar sınırlıdır. Bu bağlamda, Bursa ili özelinde 2001-2022 dönemini kapsayan çok zamanlı analiz ile Destek Vektör Makineleri ve Rastgele Orman algoritmalarının Google Earth Engine ortamında karşılaştırmalı olarak değerlendirilmesi, çalışmanın literatüre özgün katkısını oluşturmaktadır. Ayrıca, indikatör faktör haritalarının sınıflandırma doğruluğuna etkisinin sistematik olarak test edilmesi, sürdürülebilir arazi planlamasına yönelik metodolojik bir çerçeveye sunmaktadır.

3. Çalışma Bölgesi

Bursa ili, Türkiye'nin kuzeybatısında, Marmara Bölgesi'nde yer almakta olup 28°10'-30°00' doğu

boylamları ile 39°45'-40°40' kuzey enlemleri arasında konumlanmaktadır. Toplam 11.027 km² yüzölçümüne sahip olan il, Türkiye'nin toplam yüzey alanının yaklaşık %1,4'lük kısmını oluşturmaktadır. Bursa, Türkiye'nin sanayi ve ticaret açısından en gelişmiş şehirlerinden biri olduğu için kentleşme oranı son 20 yılda ciddi şekilde artmıştır (Bursa Çevre ve Şehircilik İl Müdürlüğü, 2019).


Bu bağlamda, çalışmada 2001-2022 yılları arasındaki dönemde Bursa ilinde gerçekleşen AÖ/AK sınıflarındaki zamansal değişimler, Google Earth Engine (GEE) platformu ve makine öğrenmesi yöntemleri kullanılarak analiz edilmiştir. Çalışma alanı haritası Şekil 1'de verilmiştir.

4. Yöntem

Bu araştırmada, uydu verilerinin analiz edilmesi ve bölgesel ölçekte arazi kullanım değişimlerinin belirlenmesi amacıyla GEE platformundan yararlanılmıştır. Uzaktan algılama sistemleri, uzun yıllardır büyük hacimli veri kümeleri üretmekte olup, bu verilerin geleneksel yazılım paketleri ve masaüstü bilgisayar kaynaklarıyla yönetimi ve analizi oldukça güç hale gelmiştir. Bu soruna çözüm olarak Google, büyük veri analizinde karşılaşılan zorlukları aşmak amacıyla GEE adlı bulut tabanlı bir bilişim platformu geliştirmiştir. Bu platform, özellikle geniş coğrafi alanlara ilişkin yüksek hacimli verilerin işlenmesini ve çevresel değişimlerin zamansal olarak izlenmesini kolaylaştırmaktadır (Amani vd., 2020).

Bursa ili için 2001-2022 yılları arasındaki AÖ/AK sınıflarındaki zamansal değişimleri incelemek amacıyla, 1984 yılına kadar uzanan geniş bir arşive sahip Landsat uydu görüntüleri kullanılmıştır. Çalışmada analizlerin temelini oluşturmak üzere 2001, 2011 ve 2022 yılları değerlendirme dönemleri olarak seçilmiştir. Görüntü seçim sürecinde, bulut oranının %0,5'in altında olmasına özellikle dikkat edilmiştir.

2022 yılına ait analizlerde Landsat 8 Level-2 Collection 2 Tier 1, 2001 ve 2011 yıllarına ait incelemelerde ise Landsat 5 Level-2 Collection 2 Tier 1 veri ürünleri kullanılmıştır. Bu veri setlerinde, üretici tarafından atmosferik ve radyometrik düzeltmelere ilişkin ön işleme adımları uygulanmıştır (Çizelge 1).



Şekil 1- Çalışma alanı, Bursa ili.

Çizelge 1- Çalışmada kullanılan Landsat Uydu görüntülerinin bilgileri.

Uydu ve Sensörü	İşleme Seviyesi	WRS-2 Path/Row	Görüntü Tarihi
Landsat-5 TM	Collection 2 Level-2	179/32	04.06.2001
		180/32	11.06.2001
Landsat-5 TM	Collection 2 Level-2	179/32	06.10.2011
		180/32	23.06.2011
Landsat-8 OLI/TIRS	Collection 2 Level-2	179/32	13.05.2022
		180/32	20.05.2022

Bursa ilinin coğrafi olarak geniş bir alan kaplaması nedeniyle, tek bir uydu geçiş görüntüsü yeterli olmamış; bu nedenle iki farklı görüntü yolu (Path/Row) kullanılmıştır. Bu iki görüntü, Bursa il sınırlarının tamamını kapsayacak şekilde mozaiklenmiş (birleştirilmiş) ve analizlerde kullanılmıştır. Görüntülerin seçiminde bulut oranına göre filtreleme ardından, mevsimsel değişkenliğin en az olduğu dönem olan Haziran ayı tercih edilmiş, böylece bitki örtüsünün daha kararlı bir gelişim döneminde olduğu varsayılmıştır. GEE'in geniş uydu veri arşivi ve güçlü bulut tabanlı işlem gücü sayesinde, arazi örtüsü değişimleri büyük mekânsal alanlar için hızlı ve güvenilir şekilde analiz edilebilmiştir.

Ayrıca, 2001 ve 2022 yılına ait Landsat görüntülerinde, çalışma alanının tamamını kapsayan ve bulutluluk oranı düşük tek bir tarihli görüntü bulunmadığından, mozaik görüntü en yakın tarihli iki sahne kullanılarak oluşturulmuştur. Görüntü seçimi sürecinde bulut örtüsü, atmosferik gürültü (noise), radyometrik kalite ve çalışma alanını kapsama oranı temel ölçütler olarak dikkate alınmıştır. Farklı tarihlerden elde edilen sahnelerin birleştirilmesi, mozaik sınırlarında sınırlı düzeyde zamansal süreksizlik (temporal discontinuity) veya mekânsal geçiş etkileri (edge artifacts) oluşmasına neden olabilmektedir. Bu durum, özellikle arazi örtüsünün heterojen olduğu bölgelerde sınıflandırma haritalarında yerel düzeyde ani sınıf değişimleri

şeklinde gözlenebilmektedir. Ancak, tüm mozaikler sınıflandırma öncesinde görsel olarak kontrol edilmiş, bulut ve gürültü etkileri maskeleyme işlemleriyle en aza indirgenmiş ve sınıflandırma sonuçları genel eğilimleri temsil edecek biçimde değerlendirilmiştir.

4.1. Görüntü İyileştirme Yöntemleri

4.1.1. TBA

Uzaktan algılama kapsamında elde edilen uydu görüntülerinin işlenmesinde TBA, sıklıkla kullanılan istatistiksel yöntemlerden biridir. Bu teknik genellikle demir oksit ve hidroksil mineralleri gibi yüzey bileşenlerinin haritalanmasında tercih edilmektedir (Kargı, 2007).

TBA, geniş veri kümelerinde yer alan bilgi içeriğini daha küçük, daha yönetilebilir ve kolay yorumlanabilir bir veri seti hâline dönüştürmeye imkân tanıyan bir boyut indirgeme yöntemidir (Albayrak ve AYTEK, 2022). Bu yöntem, ilişkili multispektral verilerin boyutsallığını azaltmak amacıyla temel bileşen dönüşümü uygular. Analiz sürecinde, değişkenler arasındaki korelasyonları ortadan kaldıran doğrusal kombinasyonlar (özvektör yükleri) oluşturulur. Her bir temel bileşen, bir öncesine göre daha düşük varyans değerine sahip olacak biçimde seçilir (Abhary ve Hassani, 2016).

TBA'nın güçlü bir türevidir olan özellik odaklı temel bileşen seçimi (Feature-Oriented Principal Component Selection - FPCS) ya da diğer adıyla Crosta tekniği, farklı litolojik ve çevresel özelliklerin haritalanmasında başarılı bir şekilde uygulanmaktadır (Din vd., 2021). Bu teknik, uydu görüntülerinde hedeflenen bileşenlerin yansıma ve soğurma bantları esas alınarak belirli bant kombinasyonları üzerinde yürütülür. FPCS yaklaşımında, özvektör yüklerinin analizi sonucunda hedeflerin teorik spektral imzalarıyla ilişkili bilgileri yoğunlaştıran temel bileşenler belirlenir ve bu bileşenler hedef alanların yansıması olarak değerlendirilir (Traore vd., 2020).

4.1.2. Bant Oranlama

Spektral bantlar arasındaki farkları artırmak ve topoğrafik etkilerin görüntü üzerindeki olumsuz yansımalarını azaltmak amacıyla bant oranlama ya da bant kombinasyonları yöntemi etkili bir biçimde

uygulanabilmektedir. Bir spektral bantın diğerine oranlanması, bantlar arasındaki göreceli yoğunluk farklarını ortaya koyan yeni bir görüntü oluşturur ve böylece spektral farklılıkların daha belirgin hâle gelmesini sağlar (Traore vd., 2020).

Bant oranlama ile elde edilen görüntülerin kalitesi, kullanılan bantların seçiminde büyük ölçüde hedeflenen yüzey bileşenlerinin spektral imzalarıyla ilişkilidir (Moradi ve Boomeri, 2017; Sevimli, 2021; Pour ve Hashim, 2015).

4.2. Makine Öğrenme Yöntemleri

Günümüzde, hava ve uydu tabanlı görüntülerin analizi için çok sayıda farklı yöntem geliştirilmiştir (Mountrakis vd., 2011). Bu analiz süreci, oldukça karmaşık öğrenme prosedürlerini içermektedir. Makine öğrenmesi, biyolojik öğrenme mekanizmalarından esinlenen yapay zeka alanının bir alt dalını oluşturmaktadır. Bu yaklaşım, makinelerin doğrudan verilerden öğrenmesini sağlayan algoritmaların geliştirilmesi üzerine odaklanmaktadır. Ayrıca makine öğrenmesi; veri madenciliği, karmaşık yazılım uygulamaları ve programlanması zor süreçler gibi çeşitli alanlarda etkin biçimde kullanılmaktadır (Lary vd., 2016).

Makine öğrenmesi algoritmaları, çoğu zaman “evrensel tahminçiler” olarak tanımlanır. Bu algoritmalar, incelenen sistemin temel davranışlarını bir dizi eğitim verisi üzerinden öğrenip, bu bilgiye dayanarak genelleştirilmiş tahminler yapabilmektedir. Makine öğrenmesi temelli yöntemlerin dikkat çekici bir diğer özelliği ise, veriler arasındaki ilişkilerin doğası hakkında ön bilgi gerektirmeden çalışabilmeleridir (Lary vd., 2016).

Bu çalışmada, yerbilimleri ve uzaktan algılama uygulamalarında makine öğrenmesi yöntemlerinin etkili bir analiz aracı olarak kullanılabilirliği ele alınmıştır. Özellikle Rastgele Orman (RO) ve Destek Vektör Makineleri (DVM) gibi öne çıkan makine öğrenmesi tekniklerinin özellikleri değerlendirilmiş ve Bursa ili örneği üzerinden GEE platformu kullanılarak bir uygulama gerçekleştirilmiştir. Böylece, 2001-2022 yılları arasındaki dönemde bölgedeki AÖ/AK sınıflarında meydana gelen zamansal değişimler analiz edilmiştir.

4.2.1. DVM

İstatistiksel öğrenme temelli ve denetimli bir yaklaşım olan DVM, kökenlerini 1963 yılında Vladimir N. Vapnik tarafından başlatılan çalışmalara dayandırmaktadır. DVM, yapısal riski minimize ederek sınıflandırma ve regresyon problemlerinde etkin bir şekilde kullanılmak üzere geliştirilmiştir (Bergil, 2018).

Son yıllarda, DVM algoritmaları bilimsel araştırmalarda basit, sağlam ve yüksek performanslı sınıflandırma ve regresyon yöntemi olarak yaygın biçimde tercih edilmeye başlanmıştır. Ayrıca, DVM özellikle örüntü tanıma (pattern recognition) uygulamalarında araştırmacılar arasında oldukça popüler olup, bu alanda aktif bir çalışma konusu olarak öne çıkmaktadır (Cervantes vd., 2020).

Çeşitli sınıflandırma çalışmalarında, DVM'nin genelleme performansının rakip yöntemlerle kıyaslandığında çoğu zaman daha üstün veya eşdeğer düzeyde olduğu belirtilmiştir. Bunun yanı sıra deneysel bulgular, DVM sınıflandırıcılarının özellikle yüksek boyutlu veri setlerinde diğer yöntemlere kıyasla daha başarılı sonuçlar verdiğini göstermektedir (Özkaya, 2006).

4.2.2. RO

Bir diğer önemli makine öğrenme yöntemi olan RO algoritması, yüksek performansı nedeniyle birçok sınıflandırma ve regresyon odaklı çalışmada tercih edilmektedir. RO'nun yapısı, farklı disiplinlerde uygulanabilmesine olanak tanımakta ve kullanım alanı giderek artmaktadır (Akar ve Güngör, 2012).

Sınıflandırma görevlerinde sağladığı başarılı sonuçlar sayesinde, RO algoritması toplu öğrenme yöntemlerine kıyasla daha sık kullanılmaktadır. Özellikle, toplu öğrenme yöntemleri arasında hız ve doğruluk açısından öne çıkan Bagging (Torbalama) (Breiman, 1996) ve Boosting (Hızlandırma) (Freund ve Schapire, 1996) yöntemlerine göre RO, genellikle daha üstün performans göstermektedir (Özdarıcı vd., 2011; Guo vd., 2022).

RO algoritması, yüksek doğruluk ve güçlü sınıflandırma performansı sayesinde, uzaktan algılama uygulamalarında da popüler bir yöntem haline

gelmiştir (Belgiu ve Drăguț, 2016). Bu algoritmanın bir diğer avantajı, eğitim örneklerinin kalitesi ve aşırı uyum (overfitting) sorununa karşı diğer makine öğrenmesi sınıflandırıcılarına göre daha dayanıklı olmasıdır (Belgiu ve Drăguț, 2016).

Özellikle örnek özelliklerinin yüksek boyutlu olduğu durumlarda, RO hâlâ verimli çalışabilmekte ve aşırı uyum problemini azaltarak modelin genel tahmin performansını iyileştirmektedir (Guo vd., 2022).

5. Metodoloji

Önişleme adımlarının doğruluğu zamansal değişimlerin izlenmesinde oldukça büyük önem taşımaktadır. Çalışmada kullanılan Collection 2, Level 2 düzeyindeki yüzey yansıtım (surface reflectance) görüntüleri için geometrik, radyometrik ve atmosferik düzeltmeler üretici (USGS/NASA) tarafından ön işleme aşamasında uygulanmıştır.

Bu nedenle, bu görüntülerin kullanımında ilk adım olarak ölçek faktörünün uygulanması gerekmektedir. Bir diğer ön işleme aşaması ise bulut ve bulut gölgelerinin maskeleye işlemidir. Ancak bu çalışmada, piksel bazında bulut oranı %0,5'in altında olan görüntüler tercih edildiğinden, doğrudan bulutsuz görüntüler kullanılmış ve bu aşamaya ihtiyaç duyulmamıştır. Nitekim, 2001 ve 2011 yıllarına ait Landsat görüntüleri %0 bulut oranına sahipken, 2022 yılına ait Landsat 8 görüntülerinde sırasıyla %0,11 ve %0,49 oranında bulut bulunmaktadır.

Landsat uydusunun tarama geometrisi nedeniyle Bursa ili tek bir sahada (scene) görüntülenememekte, bu nedenle görüntüler referans sistemi kapsamında 179/32 ve 180/32 numaralı satır/sütun indeksleriyle iki ayrı sahada yer almaktadır. Bu kapsamda, çalışma alanını kapsayan görüntü çiftleri mozaiklenerek tek bir birleşik görüntü haline getirilmiş ve tüm şehir sınırlarını içerecek şekilde kırpılmıştır.

5.1. AÖ/AK Haritalarının Üretilmesi

Arazi örtüsü, yeryüzünün üzerinde gözlemlenebilen bitki örtüsü, kentsel altyapı, su yüzeyleri, çıplak toprak gibi fiziksel bileşenleri ifade eder. Arazi örtüsünün belirlenmesi, sınıflandırılması ve haritalanması; çevresel izleme çalışmaları, doğal

kaynak yönetimi ve mekânsal planlama açısından büyük önem taşımaktadır.

Öte yandan arazi kullanımı, bir alanın sosyo-ekonomik işlevlerine dayalı olarak nasıl değerlendirildiğini ifade eder. Bu kapsamda; konut, sanayi, ticaret, tarım, ormancılık, rekreasyon veya koruma gibi farklı amaçlarla kullanılan alanlardan söz edilebilir.

Bu çalışmada, Bursa ilinde 2001-2022 yılları arasında meydana gelen arazi örtüsü değişimlerini incelemek amacıyla Landsat uydu görüntülerinden yararlanılmıştır. Landsat yüzey yansıtım verileri üzerinde denetimli sınıflandırma tekniklerinden DVM ve RO algoritmaları uygulanmıştır.

Arazi kullanım sınıflarının belirlenmesinde, Avrupa Çevre Ajansı (EEA) tarafından geliştirilen CORINE sınıflandırma sisteminden esinlenilmiş; bölgesel özellikler ve ihtiyaçlar dikkate alınarak altı farklı AÖ/AK sınıfı tanımlanmıştır:

- Su kütlesi,
- Orman alanı,
- Tarım alanı,
- Çorak alan,
- Kentsel alan,
- Maden ocakları,

Sınıflandırma sürecinde belirlenen eğitim sınıfları ile bu sınıflara ait örneklem ve test verilerinin sayıları, üç farklı yıl için Çizelge 2’de sunulmuştur. Tang vd.

(2011), kentsel alanların kırsal alanlara kıyasla daha heterojen bir yapıya sahip olduğunu belirtmektedir. Bu durum, sınıflandırma sırasında karşılaşılan karışık piksel (mixed pixel) problemlerinin başlıca nedenlerinden biri olarak değerlendirilebilir.

Bu çalışmada sınıflandırma modellerinin eğitimi ve doğrulanması için kullanılan referans örnekler, Landsat uydu görüntüleri ve mevcut tematik haritalar yardımıyla görsel yorumlama yöntemiyle manuel olarak seçilmiştir. Her bir AÖ/AK sınıfını temsil edecek şekilde örnekler homojen dağılım gözetilerek belirlenmiş ve sınıflar arası denge korunmuştur. Eğitim ve test veri setleri, yaygın kullanılan uygulamalara paralel olarak yaklaşık %70 eğitim ve %30 test olacak biçimde rastgele ayrılmıştır. Bu oran, modelin genellenebilirliğini artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla tercih edilmiştir. Manuel örnekleme yaklaşımı, özellikle karmaşık sınıf sınırlarının bulunduğu alanlarda otomatik örnekleme yöntemlerine kıyasla daha güvenilir referans verisi elde edilmesine olanak sağlamaktadır.

Bu çalışmada, Bursa ilinin 2001-2022 yılları arasında AÖ/AK sınıflarının belirlenmesi için spektral bantlara dayalı ve indikatör faktör haritalara dayalı (litolojik, bitki örtüsü ve kentsel) metodları ele alınmıştır.

5.1.1. Spektral bantlara dayalı AÖ/AK haritası

Bursa iline ait 2001-2022 yılları arasındaki AÖ/AK haritalarının oluşturulmasında öncelikle Landsat uydularına ait spektral bantlar kullanılmıştır.

Çizelge 2- Araştırma bölgesine ait sınıflara göre eğitim ve test örneklerinin sayısı.

Sınıflar	Eğitim Örneklerinin Sayısı			Test Örneklerinin Sayısı		
	2001	2011	2022	2001	2011	2022
Su kütlesi	2.681	1.797	4.114	5.463	1.556	3.783
Orman alanı	1.551	347	491	1.012	129	71
Tarım alanı	221	861	431	555	556	139
Çorak alan	1.496	1.403	449	141	777	546
Kentsel alan	792	543	718	541	248	616
Maden ocakları	233	441	484	163	192	169
Toplam	6.741	4.951	6.203	7.875	3.266	5.155

Analizlerde; kırmızı, yeşil, mavi, yakın kızılötesi, kısa dalga kızılötesi ve termal bantlar dahil edilmiştir. Sınıflandırma uygulamalarında DVM ve RO algoritmaları kullanılmış; elde edilen sonuçlara doğruluk analizi uygulanarak yöntemlerin performansları karşılaştırılmıştır.

5.1.2. İndikatör Faktör Haritalarına Dayalı AÖ/AK Haritası

Çalışmanın ikinci uygulamasında, TBA ile birlikte litolojik yapıların, bitki örtüsünün ve kentsel alanların belirlenmesinde etkinliği literatürde kanıtlanmış çeşitli bant kombinasyonları kullanılmıştır.

Bu kapsamda, Landsat görüntülerine TBA uygulanmış ve elde edilen birinci temel bileşen sınıflandırma aşamasında girdi olarak değerlendirilmiştir. Ayrıca, litolojik bileşenlerin uzaktan algılama ile haritalanmasına yönelik daha önce başarılı bir şekilde kullanılmış olan (Soe vd., 2005) aşağıdaki Landsat bant oranlamaları bu çalışmada da uygulanmıştır:

- **5/7:** Kil mineralleri;
- **5/4:** Demirli mineralleri (Fe^{2+});
- **3/1:** Demir oksit;

Bu bant oranlama teknikleri, sınıflandırma doğruluğunu artırmak ve farklı arazi örtüsü sınıflarını daha net ayırmak amacıyla kullanılmıştır.

Sınıflandırma doğruluğunu artırmak amacıyla, çalışmada Landsat 5 ve Landsat 8 uydu görüntüleri üzerinde NDVI ve Normalized Difference Built-up Index (NDBI) hesaplamaları yapılmıştır. Bu indeksler, bitki örtüsü ve kentsel alanların daha doğru ayırımını sağlayarak sınıflandırma algoritmalarının performansını yükseltme amacıyla kullanılmıştır.

NDVI hesaplamaları, her uydu için ilgili bant kombinasyonlarıyla aşağıdaki şekilde gerçekleştirilmiştir (Gündoğdu ve Bantchina, 2018):

$$NDVI_{Landsat8} = (Band5 - Band4) / (Band5 + Band4) \quad (1)$$

$$NDVI_{Landsat5} = (Band4 - Band3) / (Band4 + Band3) \quad (2)$$

Kentsel alanları tespit etmeye yönelik olarak Build-Up Index (BU) de analiz sürecine dahil edilmiştir.

BU, NDVI ve NDBI farkına dayalı olarak aşağıdaki şekilde tanımlanmıştır (Zha vd., 2003):

$$BU = NDBI - NDVI \quad (3)$$

NDBI hesaplamaları ise kısa dalga kızılötesi (SWIR) ve yakın kızılötesi (NIR) bantlarına dayanarak gerçekleştirilmiş olup, ilgili denklem her Landsat platformu için aşağıdaki gibidir:

$$NDBI_{Landsat8} = (Band6 - Band5) / (Band6 + Band5) \quad (4)$$

$$NDBI_{Landsat5} = (Band5 - Band4) / (Band5 + Band4) \quad (5)$$

Bu indeksler, özellikle bitki örtüsü ile kentsel yapıların ayırt edilmesinde sınıflandırma modellerine önemli katkı sağlayabilmektedir.

6. Bulgular

Bu çalışmada, Bursa ilinde son 20 yıllık süreçte meydana gelen AÖ/AK değişimleri analiz edilmiştir. Değerlendirme sürecinde, Landsat uydu görüntülerinin spektral bantları kullanılarak iki ayrı sınıflandırma yaklaşımı uygulanmıştır. Bunlardan ilki doğrudan spektral bantlara dayalı sınıflandırma iken, ikincisi belirleyici bileşenlerin ve İndikatör Faktör Haritaları'nın entegrasyonu ile gerçekleştirilmiştir.

6.1. Spektral bantlara Dayalı Bursa İli AÖ/AK Haritası

Bu çalışmada, GEE platformu kullanılarak, Landsat uydu görüntüleri üzerinden Bursa ilinde AÖ ve AK haritalar üretilmiştir. Analiz, 2001-2022 yılları arasında 10'ar yıllık periyotlar ve ayrıca üç farklı yıl için gerçekleştirilmiştir. Görüntü sınıflandırmasında, doğrusal olmayan güçlü bir sınıflandırma yöntemi olan DVM kullanılmıştır. Ayrıca, sınıflandırma performansını değerlendirmek amacıyla doğruluk analizleri yapılmış ve sonuçlar Çizelge 3'te verilmiştir.


Söz konusu yıllara ait uygulanan analiz yöntemlerinden elde edilen sınıflandırma AÖ/AK haritaları ise Şekil 2'de sunulmuştur.

6.2. İndikatör Faktör Haritalara Dayalı Bursa İli AÖ/AK Haritası

Çalışmanın ikinci uygulamasında, GEE platformu üzerinde Landsat uydu görüntülerinden elde edilen

Çizelge 3- Spektral bantlara dayalı AÖ/AK genel doğruluk analiz sonuçları.

Yıl	Yöntem	Eğitim Verisi Genel Doğruluğu (%)	Test Verisi Genel Doğruluğu (%)
2001	DVM	99,10	99,43
2001	RO	100,00	99,70
2001	DVM	99,59	86,42
2001	RO	100,00	88,49
2022	DVM	99,67	94,29
2022	RO	99,99	94,62



Şekil 2- 2001, 2011 ve 2022 için spektral bantlara dayalı Bursa AÖ/AK haritaları.

geliştirilmiş bileşenler kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Bu aşamada, sınıflandırma algoritması olarak DVM ve RO yöntemlerinden yararlanılmıştır. Uygulamada kullanılan geliştirilmiş

bileşenler; TBA'den elde edilen birinci bant, litolojik belirleyiciler olarak kullanılan bant oranları görüntüleri, ve ayrıca bitki örtüsü ve yüzey özelliklerini yansıtan NDVI ile BU indeksi görüntüleridir.


Çalışmada, indikatör faktör haritalarına dayalı Bursa ilinde 2001, 2011 ve 2022 yıllarına ait AÖ/AK haritaları üretilmiş ve DVM ile RO yöntemleriyle sınıflandırma doğruluk analizleri yapılmıştır. Çizelge 4’de eğitim ve test verisi genel doğrulukları karşılaştırmalı olarak verilmiştir.

Söz konusu yıllara ait uygulanan analiz yöntemlerinden elde edilen sınıflandırma AÖ/AK haritaları ise Şekil 3’te sunulmuştur.

Çalışmada kullanılan sınıflandırma sonuçlarının karşılaştırması ise Çizelge 5’te verilmiştir.

Çizelge 4- İndikatör faktör haritalara dayalı AÖ/AK genel doğruluk analiz sonuçları.

Yıl	Yöntem	Eğitim Verisi Genel Doğruluğu (%)	Test Verisi Genel Doğruluğu (%)
2001	DVM	99,64	100,00
2001	RO	100,00	99,81
2011	DVM	99,74	97,69
2011	RO	100,00	95,97
2022	DVM	99,43	9,66
2022	RO	100,00	98,15



Şekil 3- Bursa ilinde 2001, 2011 ve 2022 için indikatör faktör haritalara dayalı AÖ/AK haritaları.

Çizelge 5- Sonuçların karşılaştırması (*spektral bantlara dayalı,^bindikatör faktör haritalara dayalı).

Yıl	Veri	Yöntem ^a	Genel Doğruluk	Yöntem ^b	Genel Doğruluk
2001	Eğitim Verisi	DVM	99,10%	DVM	99,64%
	Test Verisi		99,43%		100%
	Eğitim Verisi	RO	100%	RO	100%
	Test Verisi		99,70%		99,81%
2011	Eğitim Verisi	DVM	99,59%	DVM	99,74%
	Test Verisi		86,42%		97,69%
	Eğitim Verisi	RO	100%	RO	100%
	Test Verisi		88,49%		95,97%
2022	Eğitim Verisi	DVM	99,67%	DVM	99,43%
	Test Verisi		94,29%		96,66%
	Eğitim Verisi	RO	99,99%	RO	100%
	Test Verisi		94,62%		98,15%

Çizelge 5 incelendiğinde, indikatör faktör haritalarına dayalı uygulamalarda sınıflandırmaların genel doğruluk oranlarında artış gözlemlenmiştir. Bu durum, spektral bantlar yerine belirleyici indikatör görüntülerin sınıflandırma analizlerine dahil edilmesinin, yöntemlerin doğruluğunu arttırabileceğini ortaya koymaktadır.


Bursa ilinde, 2001, 2011 ve 2022 yılları baz alınınca, AÖ/AK sınıflarda gerçekleşen değişiklikler İndikatör Faktör Haritaları'na dayalı DVM ve RO yöntemleri ile Şekil 4'te verilmiştir.

DVM yöntemiyle elde edilen sonuçlara göre, Bursa ili genelinde 2001-2022 yılları arasında su kütlesi, orman alanları ve maden ocaklarında hafif dalgalanmalar tespit edilmiştir. Bununla birlikte, tarım

alanlarında belirgin bir artış, çorak alanlarda hızlı bir azalma ve özellikle 2022 yılında kentsel alanlarda dikkat çekici bir artış gözlemlenmiştir.

RO yöntemiyle gerçekleştirilen sınıflandırma sonuçları ise, su kütleleri ve tarım alanlarında sınırlı dalgalanmalar olduğunu göstermektedir. Ancak bu yöntemde, ormanlık alanlarda azalma, çorak alanlarda artış, maden ocaklarında belirgin bir azalma ve kentsel alanlarda hızlı bir artış tespit edilmiştir.

DVM ve RO yöntemlerinin sınıflandırma performansları karşılaştırıldığında, DVM yönteminin Bursa bölgesindeki AÖ/AK değişikliklerini belirlemede daha yüksek doğruluk sağladığı görülmektedir. GEE platformunun uydu görüntülerini işleme ve sınıflandırmadaki güçlü kapasitesi de



Şekil 4- Bursa ilinde, AÖ/AK sınıflarda gerçekleşen değişiklikler.

göz önünde bulundurulduğunda, genel doğruluk analizlerinde her iki yöntem için de yukarı yönlü bir başarı eğilimi ortaya çıkmıştır. Elde edilen bulgular doğrultusunda aşağıdaki sonuçlara ulaşılmıştır:

- Doğruluk analizleri dikkate alındığında, DVM yöntemi, RO yöntemine kıyasla daha yüksek sınıflandırma başarısı göstermektedir.
- İndikatör faktör haritalarının kullanılması, sınıflar arasındaki ayrımı güçlendirmiş ve sınıflandırma performansını artırmıştır.

Bu bulgular, uzaktan algılama ve GEE tabanlı sınıflandırma çalışmalarında hem yöntem seçiminin hem de veri seti niteliğinin analiz sonuçları üzerindeki belirleyici etkisini açıkça ortaya koymaktadır.

7. Tartışma

Uzaktan algılama bilimi ve teknikleri, uzay tabanlı platformlar aracılığıyla yersel olaylara ilişkin uzaysal bilgi ve detaylı ham veri üretiminde kritik bir rol üstlenmektedir. Bu teknoloji, arazi örtüsünün izlenmesi için yeni araçlar ve fırsatlar sunmakta, farklı coğrafi bölgelerden elde edilen veriler değişimlerin karakterizasyonunu ve değerlendirilmesini kolaylaştırmaktadır. Uzaktan algılama verilerinin sahip olduğu uzamsal, zamansal ve spektral özellikler, arazi kaynakları yönetiminde karar destek mekanizması olarak ve arazi örtüsündeki değişimlerin haritalanmasında etkin biçimde kullanılmaktadır (Yadav vd., 2013).

Etkin bir uzaktan algılama görüntü sınıflandırması, arazi kullanımı ve arazi örtüsü sınıflarına ilişkin uzaysal-zamansal bilgilerin çıkarılmasını kolaylaştırır. Arazi kullanım/örtüsü değişimlerinin haritalanması, farklı sosyoekonomik ve çevresel faktörlerin Dünya yüzeyine etkilerinin analiz edilmesine imkân tanımaktadır (Amini vd., 2022).

Doğru ve güncel AÖ/AK haritaları, Dünya'nın dinamiklerinin izlenmesi, planlanması ve yönetilmesinde güvenilir bilgi sağlaması açısından büyük önem taşımaktadır. Bulut bilişim platformları, zaman serisi öznitelik çıkarma teknikleri ve makine öğrenme sınıflandırıcılarının kullanımı sayesinde,

daha doğru ve geniş ölçekli AÖ/AK haritaları üretilebilmektedir (Nasiri vd., 2022).

Kentsel yenileme alanlarının çevresindeki bölgelerde meydana gelen değişimler, beraberinde arazi örtüsü değişikliklerini de getirmektedir. Kent çevresindeki arazinin kullanım şekli, bölge ve şehir ekonomisinin gereksinimlerine göre şekillenmektedir. Bu değişimler genellikle periyodik olarak ortaya çıkar ve uydu görüntüleri aracılığıyla izlenip analiz edilmesi, gelecekteki müdahaleler için değerli veri sağlamaktadır. Ayrıca uzaktan algılanan görüntüler, arazi örtüsünün anlık ve sinoptik ölçekte kullanımını mümkün kıldığı için, kentsel yerleşim alanlarının dağılımı, genişleme eğilimleri ve yönetimi açısından da önemli bir araçtır.

Bu çalışmada, analizler sonucunda, son 20 yılda su kütleleri, tarımsal alanlar, kentsel alanlar, çorak araziler, maden ocakları ve orman alanları üzerindeki değişimler başarıyla haritalanmıştır. Bununla birlikte, sınıflar arası farklılıkların düşük olduğu ve spektral imzaların birbirine yakın olduğu durumlarda (örneğin orman ve tarım alanları) sınıflandırmalarda karışıklık meydana gelebilmektedir. Bu nedenle, spektral çözünürlüğü daha yüksek görüntülerin veya bileşenlerin spektral özelliklerini ayırtılabilen hava/uzay görüntülerinin kullanılması, sınıflandırma performansını artıracaktır.

Ayrıca, görüntü iyileştirme tekniklerinin uygulanması ve ilgili bileşenlerin özelliklerini daha belirgin hâle getirebilecek farklı indikatör haritalarının geliştirilip kullanılması, değerlendirmelerde daha yüksek doğruluk ve güvenilirlik sağlayacaktır.

Tartışma kapsamında, çalışmada kullanılan mozaikleme yaklaşımının sonuçlar üzerindeki olası etkileri dikkate alınmalıdır. Farklı tarihlere ait Landsat sahnelerinin birleştirilmesi, her ne kadar veri boşluklarını gidermede etkili bir yöntem olsa da, özellikle fenolojik farklılıklar, güneş açısı değişimleri ve atmosferik koşullardaki varyasyonlar nedeniyle spektral tutarlılıkta sınırlı sapmalara yol açabilmektedir. Bu durum, mozaik sınırlarına yakın bölgelerde sınıflandırma doğruluğunu yerel ölçekte olumsuz etkileyerek, bazı arazi örtüsü sınıflarının olduğundan farklı temsil edilmesine neden olabilir.

Özellikle heterojen yapıya sahip alanlarda gözlenen ani sınıf geçişleri, zamansal süreksizliğin bir yansıması olarak değerlendirilebilir. Bununla birlikte, uygulanan ön işleme adımları (bulut maskeleyme, görsel kalite kontrol ve uygun görüntü seçimi) bu etkileri önemli ölçüde azaltmıştır. Dolayısıyla elde edilen sınıflandırma sonuçlarının, yerel ölçekli belirsizlikler içermekle birlikte, çalışma alanının genel arazi örtüsü dinamiklerini güvenilir biçimde yansıttığı söylenebilir. Ancak, gelecekteki çalışmalarda daha homojen zaman serileri veya çoklu tarihli kompozit yaklaşımlar kullanılarak bu tür mozaik kaynaklı belirsizliklerin daha da minimize edilmesi önerilmektedir.

8. Sonuç

Bu çalışmada, Bursa ilinde 2001, 2011 ve 2022 yıllarına ait AÖ/AK değişimleri, Google Earth Engine ortamında uygulanan DVM ve RO algoritmaları kullanılarak analiz edilmiştir. Sınıflandırmalar iki farklı veri yaklaşımı üzerinden gerçekleştirilmiştir: (i) doğrudan spektral bantlara dayalı sınıflandırma ve (ii) NDVI, yerleşim indeksi ve bant oranları gibi türetilmiş indikatör faktör haritalarına dayalı sınıflandırma.

Genel doğruluk (Overall Accuracy) sonuçları, her üç yıl için de eğitim verilerinde her iki algoritmanın %99'un üzerinde performans gösterdiğini ortaya koymuştur. RO algoritması tüm yıllarda eğitim verisinde neredeyse %100 doğruluk sağlamış, bu durum modelin yüksek öğrenme kapasitesini göstermiştir. Ancak test verileri incelendiğinde, özellikle 2011 yılı için spektral bantlara dayalı sınıflandırmalarda doğruluk oranlarının belirgin biçimde düştüğü görülmektedir (DVM: %86,42; RO: %88,49). Buna karşılık, indikatör faktör haritaları kullanıldığında aynı yıl için doğruluk oranları önemli ölçüde artmıştır (DVM: %97,69; RO: %95,97). Bu sonuç, türetilmiş spektral indekslerin sınıflar arası ayrımı güçlendirdiğini ve modelin genellenebilirliğini artırdığını göstermektedir.

2001 ve 2022 yıllarında da benzer bir eğilim gözlenmiş; indikatör faktör haritalarına dayalı sınıflandırmalar test verisinde daha yüksek veya daha

dengeli sonuçlar üretmiştir. Özellikle 2022 yılı için RO algoritmasının indikatör tabanlı yaklaşımda %98,15 test doğruluğuna ulaşması, yöntemin karmaşık ve heterojen arazi desenlerini ayırt etmede yüksek performans sergilediğini ortaya koymaktadır. Genel olarak RO algoritmasının test verilerinde DVM'ye kıyasla daha istikrarlı sonuçlar verdiği, ancak bazı sınıflarda (özellikle orman alanlarında) DVM'nin daha dengeli ayırım sağlayabildiği gözlenmiştir.

Sınıf bazlı değerlendirmelerde su kütleleri, kentsel alanlar ve maden sahalarının yüksek doğrulukla ayrıştırılabildiği; buna karşın orman ve tarım alanlarının özellikle spektral benzerlik gösteren bölgelerde zaman zaman karışabildiği belirlenmiştir. 2011 yılında test doğruluğunda görülen düşüşün, hem görüntü kalitesi hem de arazi örtüsündeki geçiş alanlarının artışıyla ilişkili olabileceği değerlendirilmektedir. Bu durum, yalnızca ham spektral bantların kullanımının bazı dönemlerde sınırlı kalabileceğini, ancak indikatör faktör haritalarının sınıflandırma performansını belirgin biçimde iyileştirdiğini göstermektedir.

Zamansal analiz sonuçları, 2001-2022 döneminde çorak alanların azalırken tarım, kentsel alan ve maden sahalarının artış eğiliminde olduğunu ortaya koymuştur. Bu değişim, özellikle kentleşme baskısı ve ekonomik faaliyetlerin arazi kullanım desenlerini yeniden şekillendirdiğini göstermektedir. Elde edilen bulgular, sürdürülebilir arazi planlaması açısından AÖ/AK değişimlerinin düzenli olarak izlenmesinin gerekliliğini ortaya koymaktadır.

Sonuç olarak, bu çalışma makine öğrenmesi algoritmalarının bulut tabanlı bir platformda türetilmiş spektral göstergelerle birlikte kullanılmasının sınıflandırma doğruluğunu artırdığını göstermektedir. Özellikle indikatör faktör haritalarının modele entegre edilmesi, test verisi performansını anlamlı biçimde yükseltmiştir. Bu yaklaşım, orta çözünürlüklü uydu verileriyle büyük ölçekli alanlarda güvenilir AÖ/AK haritalarının üretilebileceğini ortaya koymakta ve gelecekte daha yüksek mekânsal çözünürlüklü veriler ve daha geniş eğitim veri setleriyle geliştirilebilecek metodolojik bir çerçeve sunmaktadır.

Değerlendirilen Belgeler

- Abhary, A., Hassani, H. 2016. Mapping hydrothermal mineral deposits using PCA and BR methods in Baft 1:100000 Geological Sheet, Iran. *International Journal of Advanced Engineering, Management and Science (IJAEMS)* 2(9), 1433-1438.
- Akar, Ö., Güngör, O. 2012. Classification of multispectral images using Random Forest algorithm. *Journal of Geodesy and Geoinformation* 1(2), 105-112. doi: 10.9733/jgg.241212.1.
- Albayrak, T., Aytek, A. İ. 2022. Bill variation of captive and wild chukar partridge populations: Shape or size. *Diversity* 14(1), 48. doi.org/10.3390/d14010048.
- Al-Rawashdeh, S., Saleh, B., Hamzah, M. 2006. The use of Remote Sensing Technology in geological Investigation and mineral Detection in El Azraq-Jordan. In *Cybergeo. OpenEdition*. doi: 10.4000/cybergeo.2856.
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M. 2020. Google Earth Engine Cloud Computing Platform for remote sensing big data applications: A comprehensive review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13, 5326-5350. doi: 10.1109/jstars.2020.3021052.
- Amini, S., Saber, M., Dastjerdi, H. R., Homayouni, S. 2022. Urban Land Use and Land Cover change analysis using Random Forest classification of Landsat time series. *Remote Sensing* 14 (11), 2654. doi: 10.3390/rs14112654.
- Babakan, S., Oskouei, M. M. 2014. Integrated use of multispectral remote sensing and GIS for primary gold favorability mapping in Lahroud region (NW Iran). *Journal of Tethys* 2 (3), 228-241.
- Bakr, N., Weindorf, D. C., Bahnassy, M. H., Marei, S. M., El-Badawi, M. M. 2010. Monitoring land cover changes in a newly reclaimed area of Egypt using multi-temporal Landsat data. *Applied Geography* 30(4), 592-605. doi: 10.1016/j.apgeog.2009.10.008
- Başaran, N. 2021. Orman alanları değişimlerinin google earth engine ile incelenmesi: Akdeniz bölgesi örneği. Yüksek Lisans Tezi, Eskişehir Teknik Üniversitesi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Eskişehir.
- Belgiu, M., Drăguț, L. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114, 24-31.
- Bergil, E. 2018. EEG işaretlerinin epileptik nöbet kestiriminde modern yöntemlerle analizi ve sınıflandırılması. Doktora Tezi, Sakarya Üniversitesi 130, Sakarya.
- Breiman, L. 1996. Bagging predictors. *Machine Learning* 24 (2), 123-140.
- Bursa Çevre ve Şehircilik İl Müdürlüğü. 2019. Türkiye Cumhuriyeti Bursa Valiliği, Çevre ve Şehircilik İl Müdürlüğü, Bursa İli 2018 Yılı Çevre Durum Raporu, Bursa.
- Büyüksağış, İ. S., Gürsoy, M. 2017. Uzaktan algılama yöntemiyle örnek bir maden sahasının analizi. *El-Cezerî Fen ve Mühendislik Dergisi* 4 (3), 518-540.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., Lopez, A. 2020. A comprehensive survey on Support Vector Machine classification: Applications, challenges and trends. *Neurocomputing* 408, 189-215. doi: 10.1016/j.neucom.2019.10.118.
- Din, S.U., Muhammad, K., Khan, M.F.A., Bashir, S., Sajid, M., Khan, A. 2021. Fusion of Feature Oriented Principal Components of multispectral data to map granite exposures of Pakistan. *Applied Sciences* 11(23), 11486. doi: 10.3390/app112311486.
- Freund, Y., Schapire, R.E. 1996. Experiments with a new boosting algorithm. *Proceedings of the 13th International Conference of Machine Learning, USA*.
- Guo, X., Ye, J., Hu, Y. 2022. Analysis of Land Use change and driving mechanisms in Vietnam during the period 2000-2020. *Remote Sensing* 14 (7), 1-17. doi: 10.3390/rs14071600.
- Gündoğdu, K. S., Bantchina, B. B. 2018. Landsat Uydu görüntülerinden NDVI değer dağılımının parsel bazlı değerlendirilmesi, Uludağ Üniversitesi Ziraat Fakültesi Çiftlik Arazisi Örneği. *Bursa Uludağ Üniversitesi Ziraat Fakültesi Dergisi* 32 (2), 45-53.
- Kargı, H. 2007. Principal components analysis for borate mapping. *International Journal of Remote Sensing* 28 (8), 1805-1817.
- Lary, D. J., Alavi, A. H., Gandomi, A. H., Walker, A. L. 2016. Machine learning in geosciences and remote sensing. *Geoscience Frontiers* 7 (1), 3-10. doi: 10.1016/j.gsf.2015.07.003.

- Moradi, R., Boomeri, M. 2017. Remote sensing detection of altered zones associated with Cu-Mo mineralization in North of Zahedan, SE Iran using Landsat-8 data, Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi Bülteni. Yerbilimleri 38 (3), 275-294.
- Mountrakis, G., Im, J., Ogole, C. 2011. Support Vector Machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (3), 247-259. doi: 10.1016/j.isprsjprs.2010.11.001.
- Nasir, S., Rajendran, S. 2017. Review of the role of remote sensing applications in mineral exploration and sustainable development in Oman. *International Journal of Environment and Sustainability* 6(3), 24-55.
- Nasiri, V., Deljouei, A., Moradi, F., Sadeghi, S. M. M., Borz, S. A. 2022. Land Use and Land Cover mapping using Sentinel-2, Landsat-8 satellite images, and Google Earth Engine: A Comparison of two composition methods. *Remote Sensing* 14 (9), 1977. doi: 10.3390/rs14091977.
- Özdarıcı, O. A., Akar, Ö., Güngör, O. 2011. Rastgele orman sınıflandırma yöntemi yardımıyla tarım alanlarındaki ürün çeşitliliğinin sınıflandırılması. VI. Teknik Sempozyumu (TUFUAB 2011) 1-7. Antalya, Türkiye.
- Özkaya, A. U. 2006. Intelligent arrhythmia classification based on Support Vector Machines (Master's thesis), Boğaziçi Üniversitesi, İstanbul.
- Pour, A. B., Hashim, M. 2015. Hydrothermal alteration mapping from Landsat-8 data, Sar Cheshmeh copper mining district, south-eastern Islamic Republic of Iran. *Journal of Taibah University for Science* 9(2), 155-166.
- Rajendran, S., Nasir, S. 2013. Mapping of manganese potential areas using ASTER satellite data in parts of Sultanate of Oman. *International Journal of Geosciences and Geomatics* 1/2, 92-101.
- Sevimli, U. İ., Traore, M., Topak, Y., Tekin, S. 2021. Mineral prospecting and lithological mapping using remote sensing approaches in between Yazihan-Hekimhan (Malatya) Turkey. *Bilge International Journal of Science and Technology Research* 6(1), 52-61.
- Soe, M., Kyaw, T.A., Takashima, S. 2005. Application of remote sensing techniques on iron oxide detection from ASTER and Landsat images of Tanintharyi Coastal Area, Myanmar. Akita University Faculty of Engineering and Resources Research Report 26.
- Tang, C. S., Shi, B., Gao, L., Daniels, J. L., Jiang, H. T., Liu, C. 2011. Urbanization effect on soil temperature in Nanjing, China, *Energy and Buildings* 43(11), 3090-3098. doi:10.1016/j.enbuild.2011.08.003.
- Traore, M., Çan, T., Tekin, S. 2020. Discrimination of iron deposits using Feature Oriented Principal Component Selection and Band Ratio methods: Eastern Taurus/Turkey. *International Journal of Environment and Geoinformatics (IJEgeo)* 7(2), 147-156. doi: 10.30897/ijegeo.673143.
- Uysal, M., Turgut, B., Polat, N., Dereli, M. A., Yalçın, M. 2017. Uzaktan algılama teknikleri ile açık maden ocaklarında bor minerallerinin tespiti. *AKÜ FEMÜBİD* 17, 270-276.
- Yadav, S. K., Raj, S., Roy, S. S. 2013. Remote sensing technology and its applications. *International Journal of Advancements in Research and Technology* 2 (10), 25-30.
- Zha, Y., Gao, J., Ni, S. 2003. Use of Normalized Difference Built-Up Index in automatically mapping urban areas from TM imagery. *International journal of remote sensing* 24(3), 583-594.