

Arazi Parsel Tanımlama Sistemi Verileri Kullanılarak Ülkesel Ölçekte Arazi Örtüsü ve Arazi Kullanım Sınıflandırması

Land Cover and Land Use Classification at National Scale Using Land Parcel Identification System Data (LPIS)

Fatih Fehmi Şimşek^{1*} 

¹Tarım ve Orman Bakanlığı, Tarım Reformu Genel Müdürlüğü, Ankara/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Fatih Fehmi Şimşek
fehmi.simsek@tarimorman.gov.tr

doi: 10.48123/rsgis.1268155

Yayın süreci

Geliş tarihi: 20.03.2023
Kabul tarihi: 22.05.2023
Basım tarihi: 28.09.2023

Özet

Entegre İdare ve Kontrol Sistemi (EİKS), Avrupa Birliği tarafından tarımsal desteklemelerin sevk ve idaresini sağlayan bir sistemdir. Birçok farklı bileşenden ve sistemden oluşan bu sistemin ana bileşenlerinden biri de coğrafi bir veri tabanına dayalı olan ve farklı sınıflardaki referans parselleri içeren Arazi Parsel Tanımlama Sistemi (ATPS)'dir. 2016 yılında 30 cm çözünürlüklü ortofoto görüntüler kullanılarak ülke geneli boşluk kalmayacak şekilde APTS kapsamında sayısallaştırılmıştır. Çalışmada APTS'nin kilit bileşeni olan fiziksel bloklar (13,5 milyon) ile çok zamanlı Sentinel-2 görüntüleri (370 çerçeve) kullanılarak ülke ölçeğinde arazi örtüsü ve arazi kullanım sınıflandırması yapılmıştır. Çok büyük boyutta raster ve vektör veri içeren bu çalışma, Sinergise firmasının Amazon Web Servis (AWS) içerisindeki sunucularında bulunan açık kaynak kodlu EO-Learn kütüphanesi içerisindeki LightGBM makine öğrenme algoritması kullanılarak yapılmış olup % 86,07 genel doğruluk değerine ulaşılmıştır. Sınıflandırma işlemi sonucu 2021 yılına ait arazi örtüsü ve kullanım sınıflarının belirlenmesinin yanısıra, 2016 yılında çizilen APTS sınıflarına ait fiziksel bloklar ile sınıflandırma sonucu karşılaştırılarak özellikle değişim olan alanlar ile sınıfların güncellenmesinde referans altlık olarak kullanılması da hedeflenmektedir.

Anahtar kelimeler: Arazi örtüsü ve kullanımı, APTS, Sentinel-2, Uzaktan algılama

Abstract

The Integrated Administration and Control System (IACS) is a system that provides the management and administration of the support of inspections by the European Union. One of the main components of this system, which consists of many different components and systems, is the Land Parcel Identification System (LPIS), which includes reference parcels in different classes based on a geographic database. In 2016, it was digitized within the scope of LPIS, using 30cm resolution orthophoto images, without any gaps across the country. In the study, land cover and land use classification was made at the country scale using physical blocks (13.5 million) and multi-time Sentinel-2 images (370 frames), which are the key components of the LPIS. This study, which included very large raster and vector data, was carried out using LightGBM machine learning algorithm in the open-source EO-Learn library located on the servers of Sinergise company in Amazon Web Service (AWS) and the overall accuracy value of 86.07 % was reached. In addition to determining the land cover and usage classes for 2021 as a result of the classification process, it is aimed to use the physical blocks of the LPIS classes drawn in 2016 and the classification result to be used as a reference base for updating the classes, especially in the areas with change.

Keywords: Land use and land cover, LPIS, Sentinel-2, Remote sensing

1. Giriş ve Amaç

Arazi örtüsü; tarım alanları, ormanlar, suni alanlar, sulak alanların oluşturduğu, yeryüzünün biyolojik örtüsüdür. Arazi kullanımı ise, bir alanın kullanım amacına göre (ormancılık, tarım, ticaret, sanayi) karakterize edilmesidir.

Arazi örtüsü ve kullanım haritaları, şehir planlaması, tarımsal faaliyetler, çevre ve doğal kaynak yöntemi gibi birçok uygulama için kritik bilgiler sağlamakta ve kilit bir rol oynamaktadır. Arazi örtüsü, temel iklim değişkeni olarak kabul edilmesinin yanı sıra uzaktan algılama teknolojisi ile temel biyo-çeşitlilik değişkeni olarak da önerilmektedir (Pettorelli vd., 2016). Arazi örtüsünün istenilen ölçekte görüntülenebilir olması dünya yüzeyinin kolay bir şekilde izlenmesini ve karşılaştırmalı analizler yapılmasını sağlamaktadır (Lambin ve Geist, 2006). Arazi örtüsü ve arazi kullanımı ortaya çıkarmak için birçok teknik üretilmiş ve geliştirilmiştir. Sahada çeşitli tekniklerle ölçümler yapılarak, harita üretim yaklaşımı, farklı düzeylerde ve ölçeklerde bir harita üretme yolu olup, geniş alanlar için çok zaman alıcı ve maliyetlidir (Langat vd., 2019). Diğer taraftan uzaktan algılama çalışmalarının bu hedefler için zamandan tasarruf edilerek çok daha uygun ve daha az maliyetli olduğu, yapılan çalışmalar sonucundan kendini ortaya koymuştur. Arazi örtüsü ve arazi kullanımı tespiti yapmak için sınıflandırma çalışmaları öne çıkmış, birçok metot, yöntem algoritma denenmiş ve süreç içerisinde bunlar geliştirilmiştir (Apaydın ve Abdikan, 2021). Landsat, Sentinel gibi ücretiz erişim sağlanan uydu görüntüleri ve sınıflandırma tekniklerinin makine öğrenmesi ile gelişmesi sayesinde, arazi örtüsü ve arazi kullanımı ile ilgili sınıflandırma çalışmaları daha yaygın bir hal almıştır. Özellikle çok zamanlı görüntüler ve dijital görüntü işlemedeki ilerlemeler ile arazi örtüsü kullanımının belirlenmesi ve zamansal değişiminin izlenmesi ölçekteki çalışmalarda daha efektif bir hal almıştır (Candido vd., 2021).

Konuya ilişkin olarak özellikle ölçekteki çalışmalar incelendiğinde, Verde vd. (2020) tarafından yapılan çalışmada tüm Yunanistan ölçeğinde 11 farklı sınıfa ait arazi örtüsü ve kullanım sınıflandırma çalışması yapılmıştır. Çalışmada uydu görüntüsü olarak çok zamanlı Sentinel-1 ve Sentinel-2 görüntüleri, yer doğruluk verisi olarak ise bazı sınıflar için LPIS verisi kullanılmıştır. Google Earth Engine ortamında rastgele orman algoritması ile yapılan bu çalışmada % 79.75 doğruluk seviyesine ulaşılmıştır. Lubej vd., (2019) Slovenya ölçeğinde çok zamanlı Sentinel -2 görüntüleri ile derin öğrenme algoritmasını kullanarak 10 farklı sınıf için arazi örtüsü ve kullanım çalışması yapmış olup genel doğruluk olarak % 94.5 oranında başarımlar göstermiştir. Marston vd., (2023) İngiltere sınırlarını kapsayan 21 sınıftan oluşan arazi örtüsü ve arazi kullanımı sınıflandırma çalışması yapmıştır. 1 Aralık 2020 ve 31 Ocak 2021 tarihleri arasında çekilen görüntüler kullanılmış olup sınıflandırma çalışmasında Sentinel-2'nin 60 metre bantları (B1-B9-B10) bantları hariç bütün bantları kullanılmıştır. Rastgele orman algoritması kullanılarak yapılan bu çalışma sonucunda %82.6 genel doğruluk başarımlar yakalanmıştır. Avrupa Uzay Ajansı (European Space Agency, ESA) tarafından çok zamanlı Sentinel-1 Sentinel-2 görüntüleri kullanılarak dünya ölçeğinde 11 farklı sınıf için arazi örtüsü ve kullanım çalışması yapılmış, 2651 çerçevenin kullanıldığı bu çalışma sonucunda %75 oranında genel doğruluk başarımlar sağlanmıştır (Zanaga vd., 2021). Ülkemizde bir çok arazi örtüsü ve kullanım çalışması yapılmış olup bu çalışmaların çoğu lokal yada bölgesel çalışma alanları ile sınırlı kalmakla beraber, ölçekteki yapılan en kapsamlı çalışma ise Türkiye'nin de dahil olduğu CORINE projesi kapsamında yapılan çalışmadır.

Uzaktan algılama uydularına ait mekânsal, zamansal, spektral çözünürlüğün artması ve uygulama yapılacak alanların büyük ölçekte olması durumunda, çok sayıda ve çok zamanlı görüntüleri temin etme, çeşitli görüntü işleme aşamalarından geçirme ve makine öğrenmesi ile sınıflandırma işlemleri, çok zaman almakla beraber karışık bir hal de almaktadır (Şimşek ve Durduran, 2022). Bilgisayar bilimlerindeki gelişmeler ile ortaya çıkan derin öğrenme ve makine öğrenme algoritmaları ile bu ve benzeri durumları kolaylaştıran, içerisindeki çeşitli hazır iş modellerini kullanarak büyük alanlar ya da bölgesel çalışmaları kısa sürede ve daha yüksek doğrulukta yapılmasını sağlayan uzaktan algılama kütüphanesi ve platformların ortaya çıkmasına sebep olmuştur.

EO-Learn, makine öğrenme ile derin öğrenme algoritmalarını kullanarak tarımsal ürün desen sınıflandırması, arazi örtüsü ve kullanım sınıflandırması, parsel sınırlarının otomatik olarak belirlenmesi, otomatik obje tespiti, çözünürlük arttırma vb. gibi birçok farklı uzaktan algılama çalışmasında kullanılan açık kaynak kodlu bir python kütüphanesi olup bu kütüphane Sinergise firması tarafından geliştirilmiştir (Medium, 2022a). Başta Sentinel uydularına ait görüntüler olmak üzere birçok ticari ve ticari olmayan görüntülere kütüphanesi içindeki *sentinelhub-py* python paketi kullanılarak erişim sağlanabilmektedir. Bu paket ile Sentinel-Hub servislerine bağlanarak Amazon Web Servis'lerinde (AWS) depolanan görüntülere erişim sağlanmaktadır (EO-Learn, 2022a). Kütüphane içerisinde birbiri ile uç uca bağlı ve entegre bulunan ana ve alt python paketleri sayesinde, özellikle geniş alanlarda, uzaktan algılama uygulamaları kolay, hızlı ve yarı otomatik-otomatik olarak yapılabilmektedir (Jarray vd., 2021).

Bu çalışmanın ana amacı; ölçekteki arazi örtüsü ve arazi kullanım sınıflandırması çalışması yapmak ve Entegre İdare ve Kontrol Sistemi (EİKS)'nin ana bileşenlerinden biri olan Arazi Parsel Tanımlama Sistemi (APTS)'nin güncellenmesinde de altlık bir referans veri oluşturmaktır. Bu kapsamda APTS ile oluşturulan fiziksel bloklar ve 2021 yılına ait Sentinel-2 görüntüleri ile açık kaynak kodlu EO-Learn Kütüphanesi içerisindeki LightGBM (Light Gradient Boosting Machine - Hafif Gradyan Arttırma Makineleri) algoritması kullanılarak piksel tabanlı arazi örtüsü ve arazi kullanımı sınıflandırması yapılmıştır.

Sınıflandırma sonucu ortaya çıkan sınıflar ile fiziksel blok sınıflarının karşılaştırılması sağlanmış, böylelikle APTS güncellemesine ihtiyaç duyan alanların belirlenmesi ve güncellenmesi için tüm ülke ölçeğinde altlık bir veri de üretilmiştir.

2. Arazi Parsel Tanımlama Sistemi (APTS) ve Fiziksel Blok Kavramı

EİKS, Avrupa Birliği ülkelerinde Ortak Tarım Politikası (OTP) kapsamında verilen tarımsal desteklemelerin sevk ve idaresini sağlayan bir sistemdir (Gergeli, 2008). Bu sistemin temel amacı, bilimsel metotlar kullanılarak arazi varlıklarına ait sınıfların belirlenmesi, bu sınıflar doğrultusunda kesin sınırların tanımlanması, zaman içerisinde oluşacak değişikliklerin belirlenerek, çapraz kontroller ve saha kontrolleri ile bir bilgi sistemi altında tarımsal desteklemelerin doğru bir şekilde ödenmesidir (Keser, 2007).

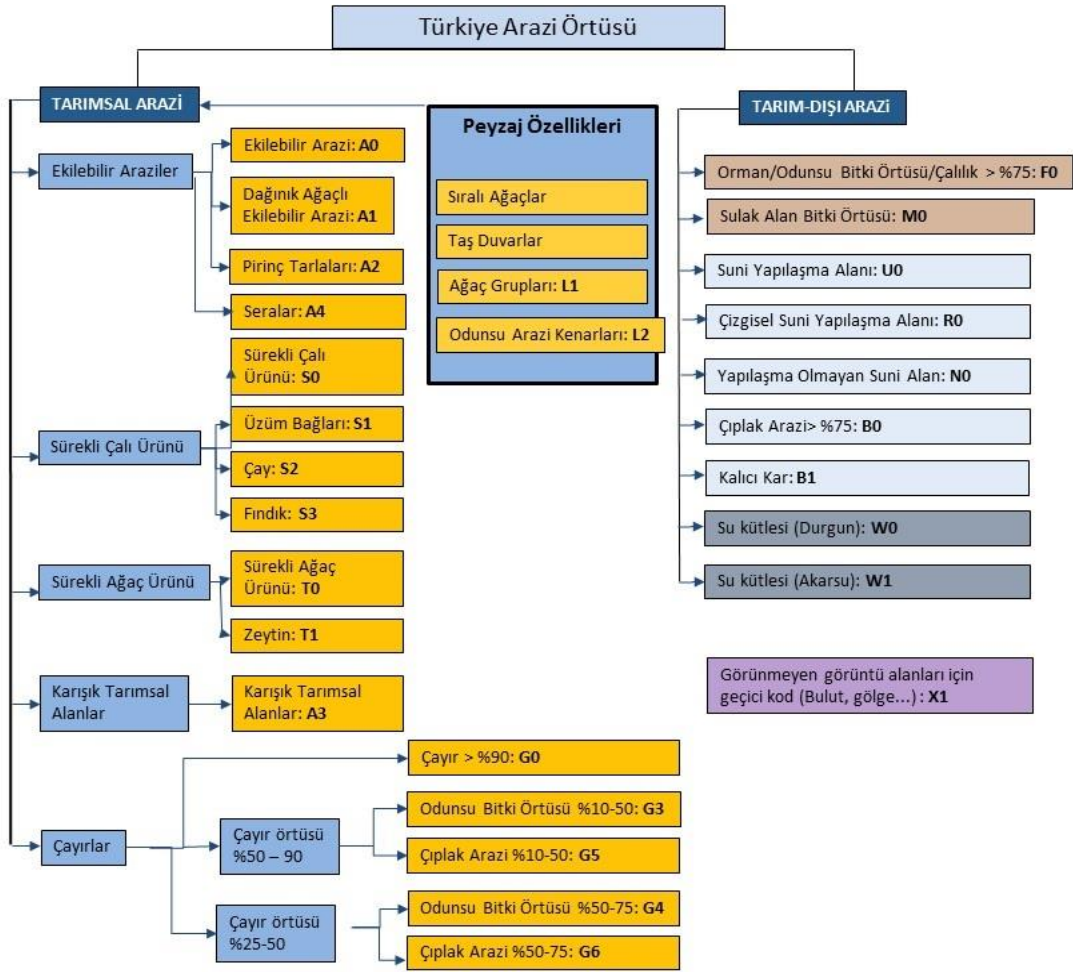
APTS, EİKS'nin alt bileşenlerinden biri olup alan bazlı destekleme için tarım parsellerinin beyan edildiği ve referans parsellerin bulunduğu coğrafi bir veri tabanıdır (Harvolk vd., 2014). APTS'nin oluşturulmasında ilk olarak referans parsel özelliğinin belirlenmesi gerekmektedir olup Avrupa Birliği bünyesindeki ülkelerde, çiftçi bloğu, kadastral parsel, tarım parseli ve fiziksel bloğu temel alan bir dizi farklı yaklaşım incelenmiş ve araştırılmıştır.

Avrupa Birliğindeki APTS'de, her bir üye ülke tarafından seçilmiş (ulusal ya da bölgesel) farklı referans parsel türlerinden (tarımsal parsel, çiftçi bloğu, fiziksel blok, kadastral sistem/topografik blok ya da bunların bir birleşimi) birini kullanmaktadır (Lüker-Jans vd., 2016). Tarım parseli, tek bir ürün grubunu kapsayan, bir çiftçi tarafından ekilen, yıllık değişiklikler gösterebilen bir referans parsel türüdür. APTS'de ürün grubunun belirlenmesinin kolay olması bir avantaj olmasına rağmen kayıtların güncel tutulmasının maliyetli olması, ürün grubunun ve parsel sınırlarının yıllık olarak değişmesinden kaynaklanan bilgilerin güncellenmesi ise tarım parseli için dezavantajdır. Çiftçi bloğu bir ya da birden fazla ürün grubuna sahip olup, bir çiftçi tarafından ekilen ve zaman içerisinde kısmen kalıcı olan bir referans parseldir. Fiziksel blok, bir veya birden fazla ürün grubunu kapsamakta olup, bir ya da birden fazla çiftçi tarafından ekilen ve yarı-kalıcı olduğu düşünülen sınırlardır. Kadastral parselleri, genellikle tarımsal üretim sınırları ile aynı geometriye sahip olmayıp, bir ya da birden fazla çiftçiye ait olup, uzun ömürlüdür. Kadastral parsellerinin en büyük avantajı tüm çiftçilerin kadastral verisine aşina olmasıdır, fakat kadastral verilerinin güncelleme sıklıklarının her yerde aynı olmaması nedeniyle tarımsal üretim yapılan arazi ile kadastral parsel sınırları arasında farklılıklar bulunmaktadır. Türkiye'de, ülkenin geniş bir alana yayılması ve tarımsal peyzajın doğal yapısı nedeniyle, APTS'nin oluşturulmasında referans parsel olarak fiziksel bloğun kullanılması uygun görülmüştür.

Bir fiziksel blok, yalnızca ulusal yönetim tarafından betimlenen (çiftçiler tarafından değil), mümkün olduğunca görülebilir olan ve nispeten kalıcı sınırlara dayanan bir üretim bloğu olarak tanımlanmıştır. Üretim bloğu, üretim yapmak veya minimum seviyede geçinmek ile ilgili, (mekânsal sürekliliği olan) tarımsal faaliyetlerin birimini, fiziksel blok ise tarımsal uygulamanın tanımlanabilir en küçük reel birimini temsil etmektedir. Fiziksel blok sınırlarının oluşturulmasında sürekli bitki deseni ve sürekli arazi örtüsü geçişi (ekilebilir arazi, çayır, sürekli bitki) geçerli sınırlar olarak kabul edilmektedir.

Kalıcı fiziksel blok sınırlarının doğru tespit edilebilmesi için bir yıl veya bir kaç yıl boyunca temin edilmiş, birden fazla görüntüye ihtiyaç duyulmaktadır. Geçmiş verilerin olmadığı durumlarda, üretim bloğu, güncel ortofoto görüntü üzerinden arazi örtüsünün yorumlanması ve ortofotoların çekildiği tarihte belirgin olan, insanlar tarafından yapılmış müdahalelerin tespiti ve bazı destekleyici bilgiler ile edilmiştir (LPIS Guideline, 2015).

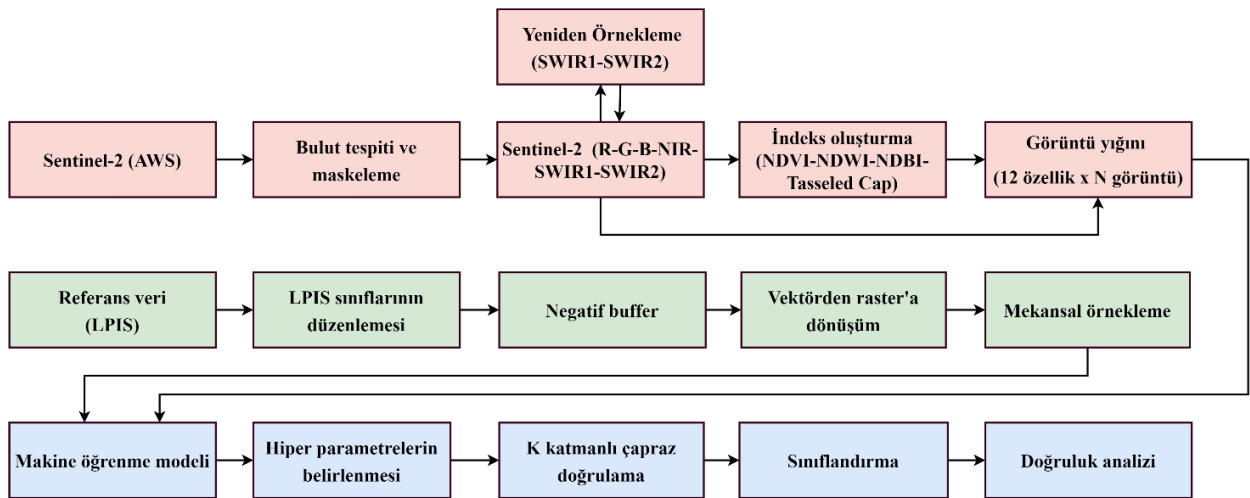
Tarım ve Orman Bakanlığı, Tarım Reformu Genel Müdürlüğü bünyesinde EİKS projesi kapsamında 2016 yılına ait 1/5000 ölçekli 30 cm mekânsal çözünürlüklü hava fotoğrafları ve uydu görüntüleri üzerinden oluşturulan standartlar kapsamında fiziksel bloklar çizilerek arazi örtüsü sınıfları belirlenmiş ve ülkesel ölçekte APTS oluşturulmuştur (Şekil 1).



Şekil 1. APTS projesinde oluşturulan arazi örtüsü sınıfları (LPIS Guideline, 2015)

3. Materyal ve Metot

Arazi örtüsü ve arazi kullanım sınıflandırmasını gösteren iş akışı Şekil 2'de gösterilmekte olup, yöntem uydu görüntülerini işleme ve özellik oluşturma, referans verinin hazırlanması ve düzenlenmesi, makine öğrenmesi ile sınıflandırma olmak üzere 3 adımdan oluşmaktadır.



Şekil 2. Sınıflandırma akış diyagramı

3.1 Uydu Görüntüsü İşleme ve Özellik Çıkarımı

Arazi örtüsü ve arazi kullanım sınıflandırması çalışmasında Sentinel-2 uydu görüntüleri kullanılmıştır. Sentinel-2 uyduları ESA tarafından Copernicus programı kapsamında uzaya fırlatılan, 5 günlük zamansal çözünürlüğe, 10 - 20 - 60 metre mekânsal çözünürlükteki 13 spektral banda sahip pasif sensörlü yer gözlem uydularıdır. Sentinel-2 görüntüleri tarım alanlarının izlenmesi, arazi örtüsü sınıflandırması, küresel gözlem, acil durum yönetimi ve su kaynaklarının gözlemlenmesi gibi geniş bir uygulama yelpazesinde kullanılmaktadır.

Ülkemizde farklı bölgelerde birçok farklı üründe tarımsal üretim gerçekleşmekte olup, kışlık ve yazlık ürünler bir arada ele alındığında ekimden hasada kadar olan tarih aralığı neredeyse tüm yılı kapsamaktadır. Yapılan bu sınıflandırma çalışmasında özellikle yıl içerisinde değişiklik gösteren ekilebilir alanların doğru bir şekilde tespit edilmesi için tek bir tarih ya da tarih aralığına ait görüntü alımı yerine, kışlık ve yazlık ürünlerin ülke genelinde en yüksek vejetatif yansıma yaptığı dönemlere ait olan mart-nisan, haziran ve ağustos-eylül tarihleri aralığını kapsayan üç farklı tarihte ülke genelini kapsayan görüntüler kullanılmıştır. Sentinel uydularına ait 128 adet çerçeve ülke genelini kapsamakta olup üç farklı tarihte görüntü alınması ve yüksek yoğunluktaki bulutlu görüntülerin elemine edilmesi sonucu sınıflandırma çalışmasında 370 adet görüntü kullanılmıştır.

Çalışmanın ülkesel ölçekte olmasından kaynaklı çok büyük boyutlu veri, veri ön işleme ve makine öğrenmesi ile sınıflandırma çalışması yapılacağından Sinergise firmasının Amazon Web Servis (AWS) içerisindeki sunucularında bulunan Sentinel-2 görüntüleri ve yine bu sunucular içerisinde bulunan açık kaynak kodlu EO-Learn kütüphanesi kullanılmıştır (AWS, 2022). EO-Learn kütüphanesinde uydu görüntülerine ait bütün bilgiler (spektral bantlar, spektral bantlardan üretilen indeksler, bulut maskeleri vb.) numpy dizisi olarak zaman serisi şeklinde her bir EO-Patch'de depolanmakta olup python paketleri tarafından herhangi bir formatta okunabilen bu bilgiler EO-Patch'lerde saklanmaktadır (Medium, 2022b; Medium, 2023). Her bir EO-Patch'de raster veri haricinde, vektör veriden raster veriye dönüştürülmüş veriler de depolanmakta olup her bir EO-Patch'de projeksiyon, tarih, meta data bilgileri bulunmakta ve bu veriler makine öğrenmesi ile derin öğrenme algoritmalarıyla sınıflandırma işlemlerinde modeli oluştururken kullanılmaktadır (EO-Learn, 2022b).

Özellikle büyük alanları kapsayan ve çok zamanlı görüntülerin kullanıldığı sınıflandırma çalışmalarında, görüntü ön işleme işlemleri ile sınıflandırma çalışması yapmak çok vakit alacak olmasının yanı sıra çok yüksek kapasitede donanım ihtiyacı da gerektirmektedir. Bu nedenle çalışma yapılacak alan homojen olarak daha küçük parçalara bölünüp (EO-Patch), bütün görüntü ön işleme adımları (atmosferik uygulamalar, bulut ile kaplı alanların tespiti, bantlardan indeks oluşturma, özellik çıkarımları ve görüntü katmanı oluşturma) ve makine öğrenmesi ile sınıflandırma işlemi her bir EO-Patch'de ayrı olarak yapılmış birleştirilmiştir (Şimşek, 2023; Skakun vd., 2022). EO-Learn içerisindeki birbirine bağlı alt paketler ile entegre bir şekilde yapılan bu işlemler standart uygulamalara kıyasla çok daha hızlı ve çok yüksek donanım kapasitesine gerek olmaksızın işlem yapılmasına olanak sağlamaktadır. Çalışma alanının boyutu, sınıf sayısı, kullanılacak görüntü sayısı ve işlem yapılacak bilgisayar ya da sunucunun donanım özellikleri gibi parametreler değerlendirilerek, kullanıcı tarafından en uygun EO-Patch boyutu belirlenebilmektedir. Bu çalışmada 10x10 km boyutunda 7800 adet EO-Patch (Şekil 3) ile yaklaşık 2TB'lık raster veri sınıflandırma çalışmasında kullanılmıştır.



Şekil 3. Ülke ölçeğinde EO-Patch'lerin görünümü

Sınıflandırma işleminde 2021 yılına ait Mart-Nisan, Haziran ve Ağustos-Eylül ayları içerisinde kalan bulutsuz görüntüler seçilmiş fakat bazı tarih aralıklarında belirli orandaki bulutlu görüntülerden kaçınılmamıştır.

Bulut ile kaplı alanlar, görüntülerdeki bantlarda ve bu bantlardan oluşturulmuş indekslerdeki piksel değerlerinde anomaliye sebep olmakta olup, bu durum sınıflandırma sonucu da olumsuz olarak etkileyebilmektedir (Karlsen vd., 2021). Yine bulutlardan kaynaklı parlamalar ve bulut kaynaklı oluşan gölgeler veri analizini olumsuz etkilemekte ve bu etkiler hem bantlardaki değerlerin hem de bantlardan oluşturulan indekslerdeki değerlerin değişmesine neden olarak, çeşitli analizler ile sınıflandırma işlemlerinde hataların gerçekleşmesine neden olmaktadır (Zhu ve Woodcock, 2012). EO-Learn kütüphanesi içerisinde bulunan Sen2cloudless paketi ile görüntü üzerindeki bulutlar otomatik olarak tespit edilmiş ve maskelenmiştir (GITHUB, 2022).

Sınıflandırma çalışmasında Sentinel-2 uydusuna ait B2 (Red), B3 (Green), B4 (Blue), B8 (NIR), B11 (SWIR-1) ve B12 (SWIR-2) bantları kullanılmıştır. Sınıflandırma çalışmasının başarısı seçilen algoritmanın yanı sıra kullanılan görüntüye ait spektral bantlar ve bu bantlardan üretilmiş indekslere de bağlı olmaktadır (Lu ve Weng, 2007). Bulutlu alanların tespit edilmesi ve maskelenmesi işlemlerinden sonra sınıflandırma işleminde kullanılacak bantlar ve bu bantlardan oluşturulan indeksler belirlenerek sınıflandırma işlemi dâhil edilmiştir. Özellikle tarım alanları, çayır ve meyve ağaçlarının tespitinde kırmızı bant ile klorofile duyarlı olan yakıl kızıl ötesi veya kırmızı kenar spektral bantları ve bu bantlardan elde edilen normalize edilmiş fark bitki örtüsü indeksi (Normalize Different Vegetation Index - NDVI) kullanılmakta olup başarılı sonuçlar vermektedir (Eitel vd., 2011). Arazi kullanımı çalışmalarında yerleşim alanları, suni ve yapay alanların belirlenmesinde normalize edilmiş yerleşim alan indeksi (Normalize Different Built Index - NDBI) de büyük bir avantaj sağlamaktadır (Zha vd., 2003). Çalışmada NDVI ve NDBI indekslerinin yanı sıra göllerin, sulak alanların ve akarsuların tespit edilebilmesi için de normalize edilmiş su indeksi (Normalize Different Water Index, NDWI) kullanılmıştır (Li vd., 2019). Bu indeksler dışında bantlara ait spektral bilgileri spektral göstergelere dönüştüren, parlaklık (Tasseled Cap Transformation Brightness - TCB), yeşillik (Tasseled Cap Transformation Greenness - TCG) ve ıslaklık (Tasseled Cap Transformation Wetness - TCW) indislerinden oluşan Tasseled Cap dönüşümleri de kullanılmıştır (ESRI, 2022; Kauth and Thomas, 1976). Tasseled Cap dönüşümleri EO-Learn kütüphanesinde varsayılan (default) indekslerdir.

Sınıflandırma çalışmasında 2021 yılına ait Mart-Nisan, Haziran ve Ağustos-Eylül ayları aralığını kapsayan 3 farklı zamanda çok bulutlu görüntülerin ayıklanması sonucu toplamda 370 adet görüntü ülke ölçeğinde sınıflandırma işlemine dâhil edilmiştir. Sentinel-2 uydusuna ait B2, B3, B4, B8, B11, B12 ile bu bantlardan oluşturulan NDWI, NDVI, NDBI ve Tasseled Cap dönüşümleri olmak üzere toplamda 12 farklı özellikten (banttan) oluşan görüntü katmanı oluşturulmuştur. Her bir görüntü alım tarihine ait 12 farklı bant bir dizi haline getirilerek sınıflandırma işleminde toplamda 36 banttan oluşan görüntü katmanı sınıflandırma çalışmasında kullanılmıştır. Zaman serisi şeklinde oluşturulan bu görüntü katmanı numpy formatında her bir EO-Patch'de depolanmış ve sınıflandırma çalışmasında girdi veri seti olarak dâhil edilmiştir. Ülke çapında yapılan bu sınıflandırma çalışmasında toplamda 7800 EO-Patch ile yaklaşık 2TB boyutunda bir veri seti sınıflandırma çalışmasında kullanılmıştır.

3.2. Fiziksel Blokların Seçimi ve Referans Veri Hazırlama

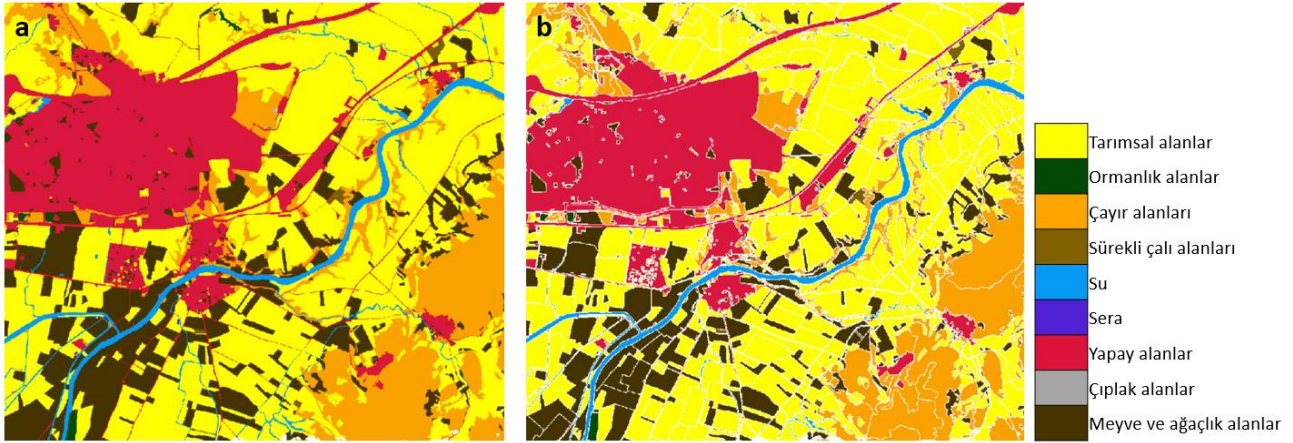
Bu çalışmada EİKS'nin alt bileşenlerinden biri olan APTS sınıfları, arazi örtüsü sınıflandırmasında referans veri olarak kullanılmıştır. Türkiye'de APTS sınıfları ekilebilir ve ekilebilir olmayan olmak üzere iki ana sınıfa ayrılmış olup toplamda 24 alt sınıftan oluşmaktadır. Bu sınıflar kendi içinde benzer ve yakın türler göz önüne alınarak gruplandırılmış ve sınıflandırma işlemi için alt sınıflar oluşturulmuştur (Tablo 1).

Oluşturulan alt sınıflardan; tarımsal alanları kapsayan 3.674.961 adet, çayır ve ekilebilir olmayan alanlardan 4.714.801 adet, çıplak ve kayalık alanlardan 103.442 adet, ormanlık alanlardan 731.417 adet, yapay alanlardan 1.860.768 adet, sera 76.174 adet, sürekli çalı alanlarından 699.793 adet, meyve ağaçları ve sürekli ağaçlık alanlardan 1.170.624 adet ve sulak ile su kaplı alanlardan 452.788 adet poligon sınıflandırma çalışmasında kullanılmıştır.

Tablo 1. Arazi örtüsü ve kullanımı sınıflandırması için oluşturulan APTS sınıf gruplandırması

Arazi Örtüsü/Kullanım Sınıfları	Orijinal sınıflar	Sınıflara ait kodlar ve açıklama
Tarımsal alanlar (A)	A0	A0-Tarım alanları
	A1	A1-Dağınık ağaçlı ekilebilir arazi
	A2	A2-Pirinç tarlaları
	A3	A3-Karma tarım alanları
Çayır ve ekilebilir olmayan alanlar (G)	G0	G0-Çayır
	G3	G3- % 50-90 çayır / % 10-50 odunsu bitki örtüsü
	G4	G4- % 25-50 çayır / % 50-75 odunsu bitki örtüsü
	G5	G5-Çayırın baskın olduğu çıplak alanlara sahip çayır
G6	G6-Çayırın baskın olmadığı çıplak alanlara sahip çayır	
Çıplak ve kayalık alanlar (B)	B0	B0-Doğal çıplak alanlar
Ormanlık alanlar (F)	F0	F0-Ormanlık/ağaçlık alanlar > % 75
Yapay alanlar (P)	N0	N0-Yapılaşma olmayan suni alanlar
	R0	R0-Yollar ve demiryolları
	U0	U0-Suni yapılaşma alanları
Sera (D)	A4	A4-Seralar
Sürekli çalılı alanları (S)	S0	S0- Makilik çalılık alanlar
	S1	S1-Üzüm bağları
	S2	S2- Çay alanları
	S3	S3-Fındık alanları
Meyve ağaçları ve ağaçlık alanlar (T)	T0	T0-Sürekli ağaçlık alanlar (özellikle meyve ağaçları)
	T1	T1-Zeytin ağaçları
Su (W)	M0	M0-Doğal sulak alanlar
	W0	W0- Su kaynakları
	W1	W1-Nehir ile ilişkili nehir kenarları

Oluşturulan sınıflara ait poligon tipindeki vektör verilerde -10 metre negatif buffer işlemi uygulanmış olup (Şekil 4) vektör formattaki veri raster formata dönüştürülmüştür. Buffer işlemi ile raster formata dönüşen veride sınıflar arasındaki sınırlardan kaynaklı gürültü ve sınır piksellerin karışması elemine edilmiştir. Raster formattaki referans verinin % 30'luk kısmına karşılık gelen pikseller (kullanıcı tarafından bu değer değişkendir) sınıflandırma çalışmasında işleminde eğitim ve test verisi olarak kullanılmak üzere rastgele ve otomatik olarak seçilmiştir.



Şekil 4. a) Oluşturulan sınıflara ait orijinal poligonlar, b) negatif tampon yapılmış gösterimi

3.3. Makine Öğrenmesi ile Sınıflandırma

Çok sayıda, boyutta ve çok zamanlı görüntüler kullanılarak yapılacak sınıflandırma çalışmalarında, bantlar, indeksler, veri hacmi, çalışma alanının boyutu, doğruluk hassasiyeti ve kullanılacak donanımın özellikleri göz önüne alındığında makine öğrenmesi ile sınıflandırma işlemi yapacak en uygun modelin belirlenmesi gerekmektedir (Şimşek ve Durduran, 2023). Bu çalışmada açık kaynak kodlu EO-Learn kütüphanesinin alt kütüphanelerinden biri olan “eo-learn-ml-tools” paketi içerisindeki LightGBM makine öğrenme algoritması kullanılmıştır. LightGBM algoritması karar ağacı algoritmalarına dayanan bir boosting algoritmasıdır (LightGBM, 2023). Yüksek işlem hızı, büyük verileri işleyebilmesi, daha az kaynak (RAM) kullanımı, yüksek tahmin oranı, paralel öğrenme ve GPU öğrenimini desteklemesi gibi avantajları ile LightGBM, XGBoost, AdaBoost gibi diğer boosting algoritmaları ile karşılaştırıldığında daha avantajlı bir konumdadır (VBO, 2023).

Makine öğrenme algoritmalarında, çalışılacak veri seti göz önüne alındığında veri setinin özelliklerine göre değişkenlik gösteren parametreler hiperparametre olarak adlandırılmaktadır. Belirlenen başarı metriğine göre en uygun parametrelerin belirlenmesi işlemi ise hiper parametre optimizasyonu olarak tanımlanmaktadır (Liu vd., 2017). Hiper parametre optimizasyonu ile oluşturulan modelde yüksek başarı sağlanması ve aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) durumlarının önüne geçilmesi amaçlanmaktadır (Guonin vd., 2017). Bu sınıflandırma çalışmasında gradyan tabanlı tek yönlü örnekleme (GOSS) parametresi hiper parametre olarak seçilmiştir. Gradyan tabanlı tek yönlü örnekleme ile örnek veri sayısının azaltılması (alt-örnekleme, downsampling) ve bu sayede verinin tümü yerine alt örneklem (subsampling) veri kümesinin kullanılması amaçlanmaktadır (Üstüner ve Balık Şanlı, 2020).

Tablo 2. LightGBM hiper parametreleri

Parametre	Değer
Hızlandırma türü	GOSS
Yapraktaki minimum veri sayısı	550
Güçlendirilmiş ağaç sayısı	100
Maksimum derinlik	20
Maksimum yaprak sayısı	200
Bölütleme sayısı	42

Sınıflandırma işleminde eğitim ve test verisi belirli bir orandaki yüzde ile manuel olarak ayrılmamış olup k-katmanlı çapraz doğrulama yöntemi kullanılmıştır. Yöntem ile çalışmada kullanılacak veri seti k sayıda parçaya ayrılarak, k-1 sayıdaki alt kümeler oluşturulan modelin eğitiminde, kalan küme ise oluşturulan modelin doğruluk oranını hesaplanmak için kullanılmaktadır. İşlem her seferinde birbirinden farklı test ve eğitim verisini kullanarak k defa tekrarlanır (Kohavi, 1995). Her bir k değeri için ortaya çıkan doğruluk değerinin ortalaması alınarak modelin doğruluğu belirlenir. Bu sınıflandırma çalışmasında fiziksel bloklardan oluşan poligon formatındaki yer doğruluk verisinin %20'si test %80'i eğitim verisi olarak kullanılmış olup k değeri 5 alınmıştır. Sınıflandırma işlemi sonucunda oluşturulan sınıflara ait duyarlılık (recall), kesinlik (precision) ve F1 skor değerleri ile genel doğruluk değeri hesaplanmıştır.

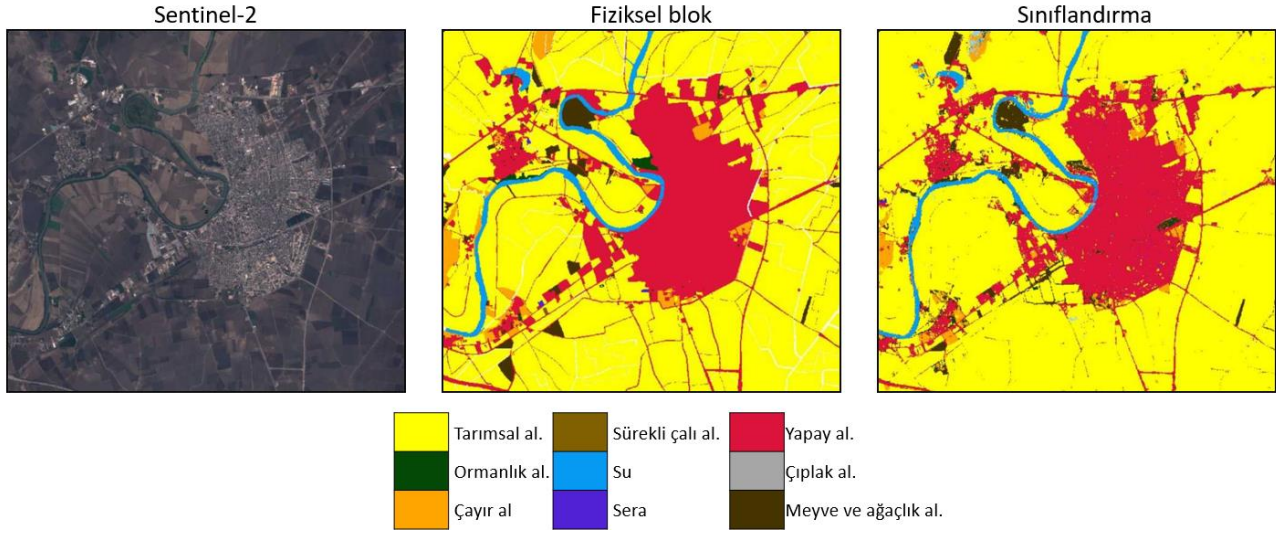
Tablo 3. Sınıflara ait hata matrisi

W	0.92	0.00	0.00	0.00	0.01	0.03	0.01	0.01	0.01
A	0.01	0.89	0.03	0.00	0.01	0.00	0.05	0.00	0.02
G	0.00	0.00	0.84	0.05	0.01	0.00	0.10	0.00	0.00
B	0.01	0.00	0.00	0.83	0.04	0.10	0.00	0.01	0.01
F	0.00	0.01	0.01	0.00	0.82	0.00	0.06	0.00	0.12
P	0.01	0.00	0.03	0.08	0.00	0.81	0.00	0.08	0.00
S	0.00	0.00	0.11	0.00	0.01	0.00	0.81	0.05	0.02
D	0.01	0.00	0.00	0.06	0.00	0.18	0.00	0.76	0.10
T	0.01	0.03	0.02	0.00	0.15	0.00	0.10	0.00	0.70
	W	A	G	B	F	P	S	D	T

Tablo 4. Sınıflara ait F1, duyarlık (recall), kesinlik (precision) değerleri

Sınıflar	F1 skor	Recall	Precision
Tarımsal alanlar (A)	89.3	87.4	90.6
Çayır ve ekilebilir olmayan alanlar (G)	83.6	85.8	81.5
Çıplak ve kayalık alanlar (B)	83.1	77.1	89.4
Ormanlık alanlar (F)	81.8	80.4	83.7
Yapay alanlar (P)	81.3	80.7	84.2
Sera (D)	76.1	78.7	73.9
Sürekli çalı alanları (S)	80.6	75.4	86.7
Meyve ağaçları ve ağaçlık alanlar (T)	71	67.9	74.7
Su (W)	91.6	90.9	92.3
Genel doğruluk	% 86,07		

Her bir sınıf tek tek incelendiğinde, su (W) ve tarımsal alanlara ait (A) sınıfların %90 doğruluk seviyesinde olduğu, çayır ve ekilebilir alanların (G) ile sürekli çalı alanlarının (S) birbirleri ile bir miktar karıştığı, çıplak ve kayalık alanlar (B) ile yapay alanların (P) %10 seviyesinde birbirleri ile karıştığı gözlemlenmiştir. Ormanlık alanlar (F) ile meyve ağaçları ve ağaçlık alanlar (T) sınıflarının ise birbirleri ile %12 seviyesinde karıştığı tespit edilmiştir. Sera (D) alanları ile yapay alanların (P) ile yaklaşık %20 civarında karıştığı görülmüş olup, yapılan inceleme sonucu 2016 yılında sayısallaştırılan seraların güncel uydu görüntüleri ile karşılaştırıldığında bir kısmının söküldüğü ve bu sebepten dolayı doğruluğun düşük olduğu tespit edilmiştir (Şekil 5).



Şekil 5. Adana İli Ceyhan İlçesine ait fiziksel bloklar ve sınıflandırma sonucunun görünümü

4. Sonuç ve Öneriler

Bu çalışmada APTS'nin ana bileşeni olan fiziksel bloklar ve çok zamanlı Sentinel-2 görüntüleri ile açık kaynak kodlu EO-Learn kütüphanesi kullanılarak ülkesel ölçekte arazi örtüsü ve arazi kullanım sınıflandırması çalışması yapılmıştır (Şekil 6). Sınıflandırma çalışmasında üç farklı zamanda (Mart-Nisan, Mayıs, Ağustos-Eylül) olmak üzere toplamda 370 adet Sentinel-2 görüntüsü ile 13.416.228 adet poligon (farklı sınıflara ait fiziksel blok) kullanılmıştır.

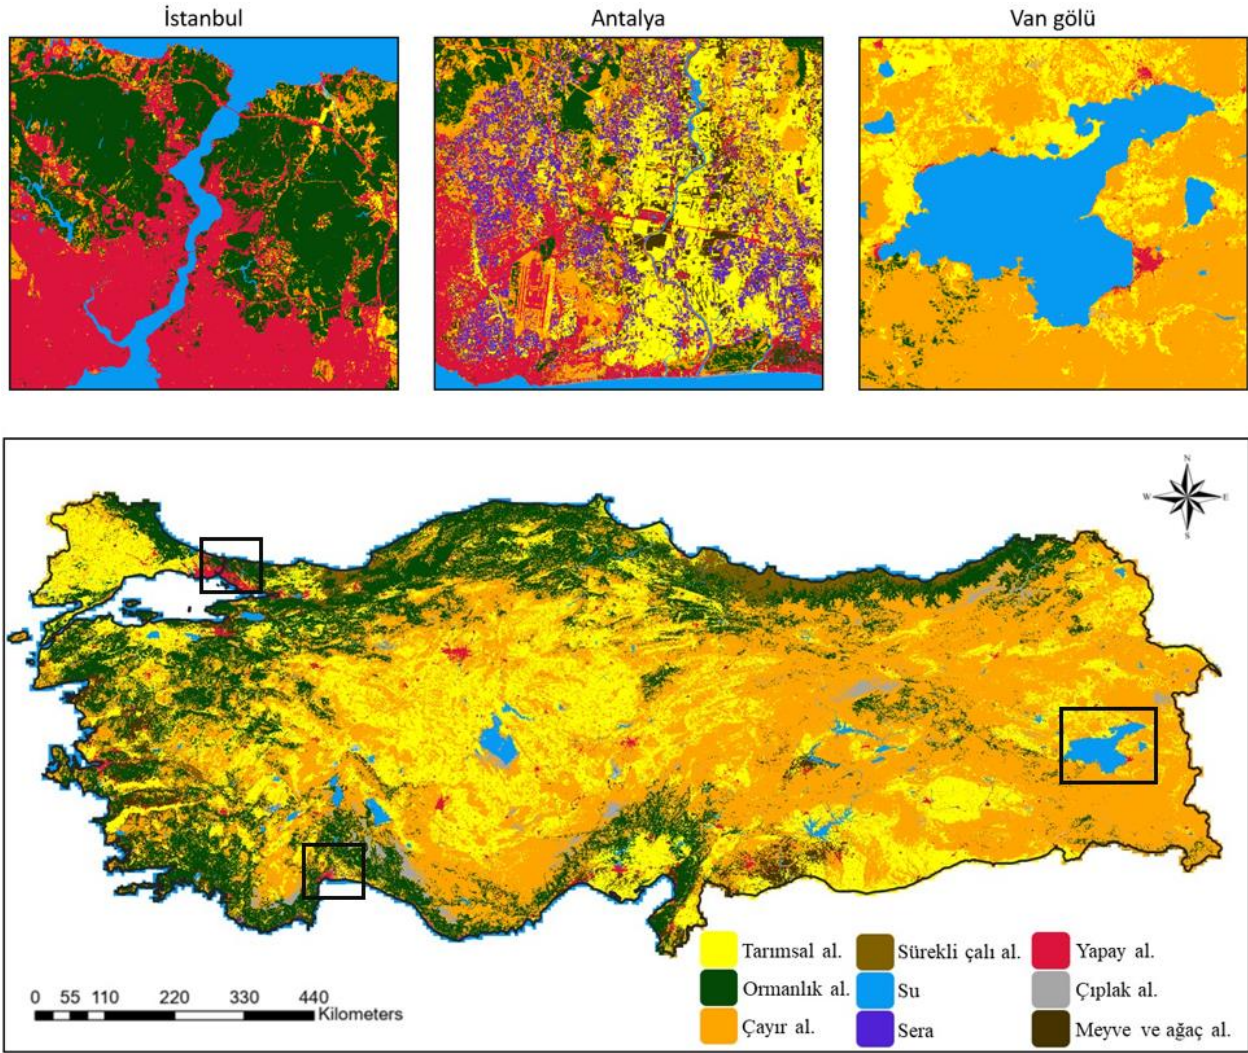
Çalışmada 2 TB boyutunda 7800 adet EO-Path (370 adet Sentinel-2) ve 45 GB boyutunda vektör veri kullanılmış olup söz konusu raster ve vektör verinin büyüklüğü ile çalışma alanının yaklaşık 780.000 km²'lik bir alanı kapsamından dolayı çok yüksek bir donanım ihtiyacı duyulduğundan lokal bilgisayarlar yerine Sinergise firmasının Amazon Web Servis (AWS) içerisindeki sunucuları kullanılmıştır (432 CPU, 848 GB RAM).

Arazi örtüsü ve kullanımının sınıflandırıldığı bu çalışmada tek bir görüntü tarihine bağlı kalınmamış olup, tarımsal alanlar, sürekli çalı alanları ve meyve ağaçları ve ağaçlık alanların daha yüksek doğrulukta tespit edilmesi sebebiyle farklı zamanlarda çekilmiş görüntüler kullanılmıştır. Sınıflandırma işleminde referans veri olarak APTS kapsamındaki 2016 yılında 30 cm'lik ortofoto görüntülerden üretilen fiziksel bloklar kullanılmış olup, eğitim veri seti olarak birbirine yakın sınıflar gruplanmıştır. Fiziksel blokların en büyük avantajı, ortofoto görüntüler üzerinden hassas bir şekilde çizilmesi olup, proje kapsamında dış kalite kontrol işlemine tabi tutulmasıdır. Dezavantajı ise yıllar içerisinde ise bazı sınıfların kendi özelliği kaybedip başka bir sınıf vasfına geçmesi olabilmektedir ki bu çalışmanın amaçlarından biri de arazi örtüsü ve kullanımı sınıflandırması sonuçları ile fiziksel blokların karşılaştırılarak değişim olan alanların tespit edilmesidir. LightGBM makine öğrenme algoritması kullanılarak yapılan sınıflandırma işlemi sonucu doğruluk analizi incelendiğinde genel doğruluğun % 86 seviyesinde olup 780.000 km² gibi çok büyük bir alanda yapılan bu çalışmanın yüksek doğrulukta sonuç verdiği görülmüştür. Su ve tarım alanlarına ait sınıflar %90 seviyesinde olup, çayır ve ekilebilir olmayan alanlar, çıplak ve kayalık alanlar, ormanlık alanlar, sürekli çalı alanları ve yapay alanlar %80-85 seviyesinde sınıflandırma doğruluğuna ulaşabilmiştir. Sera alanları %76 doğruluk seviyesinde iken meyve ağaçları ve çok yıllık ürün veren ağaçlar %71 seviyesinde kalmıştır. Diğer sınıflara kıyasla daha düşük skor veren bu sınıflar hem uydu görüntüleri hem de fiziksel bloklar ile karşılaştırıldığında, sera alanlarının özellikle yapay alanlar ile karıştığı, meyve ağaçları ile çok yıllık ürün veren ağaçlara ait sınıfın, sürekli çalı sınıfı ve orman sınıfı ile bir miktar karıştığı tespit edilmiştir.

Yapılan bu çalışma, farklı yüzölçümlere sahip bölgelerde yapılan arazi örtüsü ve kullanımı sınıflandırması çalışmaları ile karşılaştırıldığında, 780.000 km² gibi büyük bir alanı kapsayan çalışma alanında hiç bir sınıfın % 70 doğruluk değerinin altında olmaması, genel doğruluk değerinin ise %86,07 olması, çalışmanın belirli bir başarı ölçütünü yakaladığı

göstermekte ve çalışma alanları (yüz ölçümleri) ülkemize nazaran çok küçük olan Avrupa ülkelerinde yapılan çalışmalara kıyasla oranı tatmin edici seviyededir.

Yapılan çalışmaları detaylı olarak incelendiğinde, Sentinel-2 uydusuna ait girdi bant sayısının artırılması, Sentinel-1 uydusuna ait bantların girdi raster veri seti olarak kullanılması, daha fazla ya da farklı indekslerin sınıflandırmaya dahil edilmesi ve bu girdi veri setlerini kendi içinde kombine ederek farklı makine öğrenme ve derin öğrenme yöntemleri ile karar vericilere daha doğru ve güvenilir sonuçlar sunulabilecektir. Ülke ölçeğinde arazi örtüsü ve kullanımı ile ilgili yapılan en kapsamlı çalışma ise Türkiye'nin de içinde bulunduğu CORINE (Coordination of Information on the Environment) projesidir. CORINE, 44 ana sınıf ve 12 alt sınıf olmak üzere toplam 56 sınıfa ayrılmıştır. Bu sınıflar arasında; ormanlar, tarım alanları, su kaynakları, şehirler, endüstriyel bölgeler, maden ocakları ve doğal alanlar gibi farklı çevresel özellikleri temsil eden alanlar yer almaktadır. CORINE, AB ülkeleri tarafından ortak bir dil ve standartlar çerçevesinde çevresel durumun değerlendirilmesi ve raporlanması için kullanılmakta olup söz konusu bu çalışma CORINE çalışmasının bir alternatifi ya da mükerrer bir çalışma olduğu düşünülmemelidir, oluşturulan bu arazi örtüsü ve kullanımı sınıflandırması sınıf sayısı, sınıf içeriği, kullanımı amacı ve sınıflandırma ölçeği olarak da CORINE'den farklılık göstermektedir.



Şekil 6. Ülke sınırlarını kapsayan sınıflandırma sonucunun görünümü

Bu çalışmada, 2021 yılına ait Sentinel-2 görüntüleri ve fiziksel bloklar kullanılarak ülkesel ölçekte arazi örtüsü ve kullanımı sınıflandırma yapılmıştır (Şekil 6). Arazi örtüsü ve kullanımı sınıflandırması ile ekilebilir ve ekilemeyen alanlar, ormanlık alanlar, çıplak ve kayalık alanlar, yerleşim alanları ve su yüzeyi ile kaplı alanlar ülkesel ölçekte belirlenmiştir. Bu çalışmanın ana hedeflerinden birisi EİKS'nin ana bileşenlerinden biri olan destekleme ödemelerinin yönetimi ve kontrolünde referans bir sistem olan APTS'nin güncellenmesinde altlık olarak kullanılmasıdır. Ülkemizde APTS verisi 2016 yılında oluşturulmuş olup güncellenmesi gerekmektedir. Ülke ölçeğinde tüm verinin güncellenmesi işi zaman ve maliyet bakımından büyük bir iş yükü olup APTS kapsamındaki her sınıfının aynı ölçekte ve iş yükünde güncellenmesine de ihtiyaç duyulmaya bilinir (yapay alanlar, çıplak alanlar, sulak alanlar).

Ancak tarım alanları içerisindeki farklı arazi örtüsü sınıflarına sahip alanların ise güncellenmesi gerekmektedir (tarımsal alanlar, sürekli çalı alanları, meyve ve ağaçlık alanlar). EO-Learn kütüphanesi ile görüntülerin temin edilmesinden, uydu görüntüsü ön işlemlerine, eğitim verisinin seçiminden, makine öğrenmesi ile sınıflandırma işlemine kadar olan işlem adımları birbirine bağlı ve entegre iş modelleri ile bölgesel yada ülke ölçeğinde hızlı ve doğru bir şekilde yapılabilmektedir. Yapılan sınıflandırma sonucu ortaya çıkan sınıflar ile APTS sınıfları karşılaştırılarak, APTS verisinin güncellenmesi için Bakanlıkta oluşacak olan planlama ve iş yükü belirlenecek olup, muhtemel değişiklik nedeniyle en önce ve en çok hangi alanlara odaklanacağı ve nereden başlanacağı konusunda arazi örtüsü sınıflandırması altlık oluşturacaktır.

Kaynaklar

- AWS. (2022, Kasım 11). *Registry of open data on AWS*. Retrieved from <https://registry.opendata.aws/sentinel-2/>.
- Apaydın, C., & Abdikan, S. (2021). Fındık bahçelerinin Sentinel-2 verileri kullanılarak piksel tabanlı sınıflandırma yöntemleriyle belirlenmesi. *Geomatik*, 6(2), 107-114.
- Candido, C., Blanco, A. C., Medina, J., Gubatanga, E., Santo, A., Ana, R. C., & Reyes, R. B. (2021). Improving the consistency of multi-temporal land cover mapping of Laguna lake watershed using light gradient boosting machine (LightGBM) approach, change detection analysis, and Markov chain. *Remote Sensing Applications: Society and Environment*, 23(5), 100565. doi: 10.1016/j.rsase.2021.100565.
- Eitel, J. U. H., Vierling, L. A., Litvak, M. E., Long, D. S., Schulthess, U., Ager, A. A., Krofcheck, D. J., & Stoscheck, L. (2011). Broadband, red-edge information from satellites improves early stress detection in a new mexico conifer woodland. *Remote Sensing of Environment*, 115(12), 3640-3646.
- ESRI. (2022, Eylül 11). *Tasseled cap function*. Retrieved from <https://pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/tasseled-cap-function.htm>.
- EO-Learn, (2022a, Aralık 17). *Introduction EO-Learn*. Retrieved from <https://eo-learn.readthedocs.io/en/latest/#>.
- EO-Learn, (2022b, Aralık 24). *EO-Learn core is the main subpackage which implements the basic building blocks*. Retrieved from <https://eo-learn.readthedocs.io/en/latest/examples/core/CoreOverview.html#EOPatch>.
- Gergeli, B. (2008). *AB'de Entegre İdare ve Kontrol Sistemi Bilgi Teknolojileri (IT) yapısı, ödeme kuruluşu altyapısı ile olan ilişkisi ve etkileri, Türkiye'de uygulanabilirliği* (AB Uzmanlık Tezi). Tarım ve Köy işleri Bakanlığı, Dış İlişkiler ve Avrupa Birliği Koordinasyon Dairesi Başkanlığı, Ankara, Türkiye.
- GITHUB, (2022, Aralık 17). *Sentinel Hub's cloud dedector for Sentinel-2 imagery*. Retrieved from <https://github.com/sentinel-hub/sentinel2-cloud-detector>.
- Guolin, K., Men, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye Q., & Liu, T. Y. (2017, December). LightGBM: A highly efficient gradient boosting decision tree. In *31st Conference on Neural Information Processing Systems, 2017. Proceedings*. (pp. 1-9). NeurIPS.
- Harvolk, S., Kornatz, P., Otte, A., & Simmering, D., (2014). Using existing landscape data to assess the ecological potential of miscanthus cultivation in a marginal landscape. *GCB Bioenergy*, 6(3), 227-241.
- Jarray, N., Abbes, A. B., Rhif, M., Chouikhi, F., & Farah, I. R. (2021, July). An open source platform to estimate Soil Moisture using Machine Learning Methods based on Eo-learn library. In *International Congress of Advanced Technology and Engineering, 2021. Proceedings*. (pp. 1-5). IEEE.
- Kauth, R. J., & Thomas, G. S. (1976, June). The Tasseled Cap - a graphic description of the spectral - temporal development of agricultural crops as seen by LANDSAT. In *Symposium on Machine Processing of Remotely Sensed Data, 1976. Proceedings*. (pp. 41-59). IEEE.
- Karlsen, S. R., Stendardi, L., Tømmervik, H., Nilsen, L., Arntzen, I. M., & Cooper, E. J. (2021). Time-Series of Cloud-Free Sentinel-2 NDVI data used in mapping the onset of growth of central Spitsbergen, Svalbard. *Remote Sensing*, 13(15), 3031. doi: 10.3390/rs13153031.
- Kohavi, R. (1995, August). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *International Joint Conference of Artificial Intelligence, 1995. Proceedings*. (pp. 1137-1145). IJCAI.
- Keser, T. Z. (2007). *Entegre idare ve kontrol sistemi, mevcut durum ve AB üye ülkeleri arasından seçilen örnekler üzerinden incelenmesi* (AB Uzmanlık Tezi). Tarım ve Köy işleri Bakanlığı, Dış İlişkiler ve Avrupa Birliği Koordinasyon Dairesi Başkanlığı, Ankara, Türkiye.
- Langat, P. K., Kumar, L., & Koech, R. (2019). Monitoring river channel dynamics using remote sensing and GIS techniques. *Geomorphology*, 325, 92-102.
- Lambin, E. F., Geist, H. J., & Rindfuss, R. R. (2006). Local Processes with Global Impacts. In E.F. Lambin & H.J. Geist (Eds.), *Land-Use and Land-Cover Change: Local processes and global impacts* (pp. 1-8), Heidelberg: Springer Berlin.
- LPIS Guideline, (2015). LPIS data capture photo interpretation and digitization guidelines. Republic of Turkey Ministry of Agriculture and Forestry, Ankara, Turkey.

- Li, W., Ding, S., Chen, Y., Wang, H., & Yang, S. (2019). Transfer learning-based default prediction model for consumer credit in China. *Journal of Supercomputing*, 75(2), 862-884.
- LightGBM, (2023, Şubat 1). *Welcome to LightGBM's documentation*. Retrieved from <https://lightgbm.readthedocs.io/en/latest/index.html#>.
- Liu, L., Ji, M., & Buchroithner, M. F. (2017). Combining partial least squares and the gradient-boosting method for soil property retrieval using visible near-infrared shortwave infrared spectra. *Remote Sensing*, 9(12), 1299. doi: 10.3390/rs9121299.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification Performance. *International Journal of Remote Sensing*, 28(5), 823-870.
- Lubej, M., Aleksandrov, M., Batic, M., Kadunc, M., Milcinski, G., Peressutti, D., & Zupanc, A. (2019, May). Spatio-temporal deep learning: an application to land cover classification. In *ESA Living Planet Symposium, 2019. Proceedings*. (pp. 2-5). ESA.
- Lüker-Jans, N., Simmering, D., & Otte, A. (2016). Analysing data of the integrated administration and control system (IACS) to detect patterns of agricultural land-use change at municipality level. *Landscape Online*, 48(1), 1-24. doi: 10.3097/LO.201648.
- Marston, C. G., O'Neil, A. W., Morton, R. D., Wood, C. M., & Rowland, C. S. (2023). LCM2021 - The UK land cover map 2021 [preprint]. *Earth System Science Data Discussions*, doi: 10.5194/essd-2023-78.
- Medium, (2022a, Ekim 14). *Introducing EO-Learn*. Retrieved from <https://medium.com/sentinel-hub/introducing-eo-learn-ab37f2869f5c>.
- Medium, (2022b, Kasım 8). *Land cover classification with EO-Learn*. Retrieved from <https://medium.com/sentinel-hub/land-cover-classification-with-eo-learn-part-3-c62ed9ecd405>.
- Medium, (2023, Ocak 5). *Improving cloud dedection with machine learning*. Retrieved from <https://medium.com/sentinel-hub/improving-cloud-detection-with-machine-learning-c09dc5d7cf13>.
- Pettorelli, N., Wegmann, M., Skidmore, A., Mucher, S., Dawson, T., Fernandez, M., ... Geller, G. (2016). Framing the concept of satellite remote sensing essential biodiversity variables: challenges and future directions. *Remote Sensing Ecology Conservonsevation*, 2(3), 122-131.
- Üstüner, M., & Balık Şanlı, F. (2020). Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 7(1), 1-10.
- Skakun, S., Wevers, J., Brockmann, C., Doxani, G., Aleksandrov, M., Batič, M., ... Žust, L. (2022), Cloud Mask Intercomparison Exercise (CMIX): An evaluation of cloud masking algorithms for Landsat 8 and Sentinel-2. *Remote Sensing of Environment*, 274, 112990, doi: 10.1016/j.rse.2022.112990.
- Şimşek, F. F. (2023). *Çiftçi kayıt verileri ve açık kaynak koldu EO-Learn Kütüphanesi kullanılarak tarımsal ürün desen tespiti ve kontrolü* (Doktora Tezi). Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Konya, Türkiye.
- Şimşek, F. F., & Durduran, S. (2022), Land cover classification using Land Parcel Identification System (LPIS) data and open source EO-Learn library. *Geocarto International*. Advance online publication. doi: 10.1080/10106049.2022.2146760.
- Şimşek, F. F., & Durduran, S. (2023), Açık kaynak kodlu EO - Learn kütüphanesi ve çok zamanlı sentinel-2 görüntüleri ile tarımsal ürün sınıflandırması. *Jeodezi ve Jeoinformasyon Dergisi*, 10(1), 45-62.
- Verde, N., Kokkoris, I. P., Georgiadis, C., Kaimaris, D., Dimopoulos, P., Mitsopoulos I., & Mallinis, G. (2020). National scale land cover classification for ecosystem services mapping and assessment, Using Multitemporal Copernicus EO Data And Google Earth Engine. *Remote Sensing*, 12(20), 3303. doi: 10.3390/rs12203303.
- VBO. (2023, Ocak 13). *LightGBM*. Retrieved from <https://medium.com/sentinel-hub/introducing-eo-learn-ab37f2869f5c>.
- Zanaga, D., Van De Kerchove, R., De Keersmaecker, W., Souverijns, N., Brockmann, C., Quast, R., ... Arino, O. (2021). ESA WorldCover 10 m 2020 v100 [Data set]. Zenodo. Retrieved from <https://doi.org/10.5281/zenodo.5571936>.
- 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), 583-94.
- Zhu, Z., & Woodcock, C. E. (2012). Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83-94.