



Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi

<https://dergipark.org.tr/tr/pub/yyufbed>



Araştırma Makalesi

Hızlandırılmış Makine Öğrenmesi Algoritmaları ile Tarım Parseli Tabanlı Ürün Desen Sınıflandırması

Fatih Fehmi ŞİMŞEK

Tarım ve Orman Bakanlığı, 06800, Ankara, Türkiye
Fatih Fehmi ŞİMŞEK, ORCID No: 0000-0003-4016-4408
Sorumlu yazar e-posta: f.fehmi.simsek@gmail.com

Makale Bilgileri

Geliş: 09.01.2024
Kabul: 08.03.2024
Online Nisan 2024

DOI:10.53433/yyufbed.1416820

Anahtar Kelimeler

Makine öğrenmesi,
Planet scope,
Sentinel-2,
Tarım parseli,
Ürün sınıflandırma

Öz: Gelişen teknoloji sayesinde, uydu görüntüleri ve uzaktan algılama çalışmaları, tarım alanında öncü çalışmalar arasında yer almaktadır. Tarımsal ürün desen tespitinde en yaygın kullanılan yöntemlerin başında ise uzaktan algılama teknolojisi gelmektedir. Uydu görüntüleri ve uzaktan algılama teknolojisi ile oluşturulan ürün desen haritaları, Tarım ve Orman Bakanlığı tarafından destekleme ödemelerinde altlık olarak aktif bir şekilde kullanılmaktadır. Bu çalışmada, çalışma alanı olarak Eskişehir İli, Seyitgazi ve Sivrihisar İlçe sınırları içerisinde kalan alan seçilmiş, çok zamanlı Sentinel-2 görüntüleri ve hızlandırılmış makine öğrenme algoritmaları (GBM, XGBoost, LightGBM, CatBoost) kullanılarak obje tabanlı (tarım parseli) sınıflandırma çalışması yapılmış ve sonuçlar karşılaştırılmıştır. Yapılan çalışma sonucunda her bir algoritma ile %90 üzerinde genel doğruluk değerine ulaşılmıştır (GBM-%90.3, XGBoost-%91.1, LightGBM-%93.9, CatBoost-%93.5). Sınıflandırma çalışmasında Tarım ve Orman Bakanlığı tarafından oluşturulan tarım parselleri obje olarak kullanılmıştır. Çalışma sonucunda tarım parsel sınırları ile parsel içerisinde ekim yapılan alan ve sınırların bazı parsellerde farklılık gösterdiği, ayrıca bir tarım parseli içerisinde birden fazla farklı ürüne ait tarımsal üretim yapıldığı gözlemlenmiştir. Bu tarım parsellerinin sınıflandırma çalışmasında obje olarak kullanılması için parsel sınırlarının ekim yapılan alan sınırlarına göre düzenlenmesi/bölünmesi gerektiği sonucuna ulaşılmıştır. Tarım parsellerinin küçük ölçekli ve orta ölçekli alanlarda uygulanan yöntem ile kullanılabilir olduğu, geniş alanlarda ise alternatif bir yöntemin geliştirilmesi gerektiği sonucuna varılmıştır.

Agricultural Parcel Based Crop Type Classification with Boosting Machine Learning Algorithm

Article Info

Received: 09.01.2024
Accepted: 08.03.2024
Online April 2024

DOI:10.53433/yyufbed.1416820

Keywords

Agricultural parcel,
Crop classification,
Machine learning,
Sentinel-2,
Planet scope

Abstract: Thanks to the developing technology, satellite images and remote sensing studies are among the pioneering studies in the field of agriculture. Remote sensing technology is one of the most widely used methods in agricultural crop type detection. The Ministry of Agriculture and Forestry actively uses crop-type maps created with satellite images and remote sensing technology as a basis for support payments. The area within the borders of Seyitgazi and Sivrihisar Districts of Eskişehir Province was selected as the study area, object-based (agricultural parcel) classification was performed using multi-temporal Sentinel-2 images and accelerated machine learning algorithms (GBM, XGBoost, LightGBM, CatBoost) and the results were compared. As a result, the study achieved an overall accuracy of over 90% with each algorithm (GBM- 90.3%, XGBoost- 91.1%, LightGBM- 93.9%, CatBoost- 93.5%). Agricultural parcels created by the Ministry of Agriculture and Forestry were used as objects in the

classification study. As a result of the study, it was observed that the boundaries of the agricultural parcel and the cultivated area and boundaries within the parcel differed in some parcels, and it was also observed that agricultural production of more than one different crop was carried out within an agricultural parcel. In order to use these agricultural parcels as objects in the classification study, it was concluded that the parcel boundaries should be organized/divided according to the boundaries of the cultivated area. It was concluded that agricultural parcels could be used with the method applied in small and medium-sized areas, while an alternative method should be developed in large areas.

1. Giriş

Tarım alanların incelenmesi, gözlemlenmesi, verimliliğin artırılması ve kaynakların daha etkili bir şekilde kullanılmasında, gelişen teknoloji ile birlikte uzaktan algılama teknolojisi sıklıkla kullanılmaktadır. Ücretsiz temin edilen uydu görüntülerinin (Sentinel, Landsat, Modis) sayısının, uydulara ait mekânsal, zamansal ve spektral çözünürlüğünün artmasıyla tarımsal ürün desenin tespiti ve belirlenmesi, bitki su tüketimi, rekolte tahmini gibi tarımsal uygulamalar uzaktan algılama teknolojisinin en yaygın kullanıldığı alanlardan biri haline gelmiştir. Özellikle Tarım ve Orman Bakanlığı tarafından uydu görüntüleri ve bu görüntülerinden üretilen tarımsal ürün desen haritaları, destekleme ödemelerinde altlık olarak aktif bir şekilde kullanılmaktadır.

Teknolojinin gelişmesiyle sınıflandırma teknikleri, kullanılan metodolojiler, algoritmalar sürekli gelişmekte ve yenileri eklenmektedir. Sınıflandırma çalışmaları önceleri sadece piksel tabanlı çalışmalara dayanırken nesne tabanlı yöntemler de aktif olarak kullanılmaya başlanmış ve literatürde yerini almıştır. Piksel tabanlı sınıflandırma işleminde, girdi veri setini pikseller oluştururken, nesne tabanlı sınıflandırma işleminde benzer spektral özelliklerine sahip piksellerin gruplandırılarak oluşturduğu segmentler (bölütler) girdi veri seti olarak kullanılmaktadır (Tavus, 2019).

Segmentasyon (Bölütleme) yöntemlerinin kullanılması ve her geçen gün gelişmesi ile tarımsal üretim yapılan alanların uydu görüntüleriyle çıkarımını kısmen mümkün hale gelmiştir (Li, 2022). Tarımsal ürün desen belirleme çalışmalarında, kullanılacak uydu görüntüsünün mekânsal, zamansal ve spektral çözünürlüğü hem piksel hem de obje tabanlı sınıflandırma çalışmaları için çok önemlidir. Uydu görüntülerindeki mekânsal çözünürlüğün artması, görüntülerde heterojenliğinin artmasına neden olmakla birlikte, nesnelerin spektral olarak birbirine benzemesine, dolayısıyla sınıflandırma doğruluğunun yüksek seviyede olmamasına sebep olmaktadır (Antunes ve ark., 2003). Yüksek çözünürlüklü uydu görüntüleri kullanılarak oluşturulan segmentlerden (bölütlerden) tarım alanlarının çıkarımı istenilen seviyede olmasına rağmen, yüksek çözünürlüklü görüntüler ticari firmalar tarafından işletilmesi ve çok zamanlı (birden fazla) temin edilmesi gerektiğinden oluşacak yüksek maliyetler sebebiyle bu görüntülerle çalışmak sürdürülebilir değildir. Düşük çözünürlüklü görüntülerin kullanıldığı piksel tabanlı sınıflandırma çalışmalarında, bir piksel birden fazla farklı yansıma yapan tarımsal ürünlerine ait alanları içerebileceği gibi, obje tabanlı çalışmalarda ise oluşturulan segmentler (bölütler) hem farklı ürün çeşidinde olan parselleri gruplayabilmekte hem de yüz ölçümü küçük ve tarım dışı alanlar ile yapıları da segmentlerin (bölütlerin) içine dâhil edebilmektedir (Safarov ve ark., 2022).

Avrupa Uzay Ajansı (ESA) tarafından ücretsiz servis edilen, Sentinel-2 uydu görüntülerinin zamansal ve spektral çözünürlüğü ürün desen sınıflandırması için ideal olmakla beraber, mekânsal çözünürlüğü özellikle küçük alanlarda yapılan tarımsal aktiviteler için yeterli değildir. Ülkemizdeki tarım parseli büyüklüğü ortalama olarak 5 dönüm olup, Sentinel-2 görüntüleri ile obje tabanlı segmentasyon (bölütleme) sonucu oluşturulan parsel sınırlarının 5 dönüm ve altındaki alanlarda, parsel sınırları tam sağlamadığı tespit edilmiştir (Vajsova ve ark., 2020). Bahsi geçen yöntemlerdeki problemler ve sorunlar sebebiyle, sınıflandırma çalışmasında alternatif olarak Tarım ve Orman Bakanlığı bünyesindeki tarım parselleri kullanılabilirliği test edilmiştir.

Bu sınıflandırma çalışması, Sentinel-2 uydu görüntüleri, tarım parselleri ve makine öğrenme algoritmaları ile obje (nesne) tabanlı olarak yapılmıştır. Çalışmanın ana hedeflerinden birincisi tarım parsellerinin sınıflandırma çalışmasında obje olarak kullanılabilirliğinin test edilmesi, ikincisi ise son zamanlarda popüler hale gelen hızlandırılmış makine öğrenme algoritmalarının kullanılması ve performanslarının karşılaştırılmasıdır.

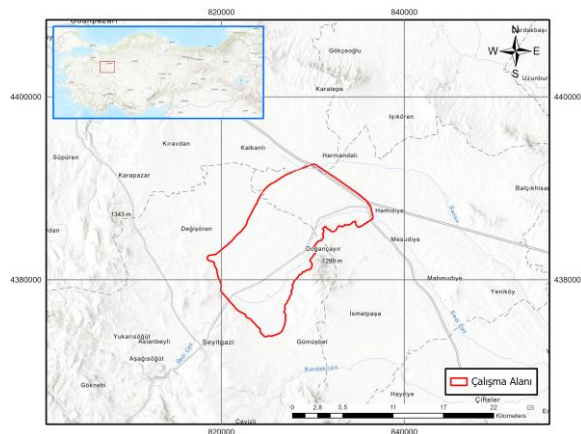
Literatürde obje tabanlı, piksel tabanlı ve her iki yöntemin uygulandığı sınıflandırma çalışmaları

ile hızlandırılmış makine öğrenme algoritmalarının kullanıldığı bir takım çalışmalar bulunmaktadır. Amerika Birleşik Devletlerinin Kaliforniya ve Teksas eyaletlerinde dinamik zaman çarpıtma algoritması ile tek ve çok zamanlı Sentinel-2 görüntülerini kullanarak obje tabanlı tarımsal ürün desen sınıflandırma çalışması yapmışlardır. Buğday, yonca, nadas, şeker pancarı, soğan ürünleri için yapılan sınıflandırma sonucunda tek bir Sentinel görüntüsü ile yapılan sınıflandırma sonucu %79.5 çok bantlı Sentinel-2 görüntüleri ile yapılan sınıflandırma sonucu %89.1 doğruluk sonucuna ulaşmış olup çok bantlı görüntülerle yapılan tarımsal ürün sınıflandırmasının daha yüksek doğruluk değerine ulaştığı sonucuna varmışlardır (Csillik ve ark., 2019). Sentinel-1 ve Sentinel-2 uydularına ait görüntüleri ile farklı makine öğrenme algoritmalarını kullanarak obje tabanlı tarımsal ürün desen sınıflandırma çalışması yapmış olup, çalışmada en yüksek doğruluğu destek vektör makineleri (DVM) %93.57 vermiş olup, en düşük doğruluk değerini karar ağacı (KA) %89.04 algoritması vermiştir. Rastgele orman (RO) algoritması ile %91.75 doğruluk değerine ulaşılmıştır (Dizdaroğlu, 2019). Vietnam’da, hızlandırılmış makine öğrenme algoritmaları ile nesne tabanlı arazi örtüsü sınıflandırma çalışması yapmışlardır. Spot-7 uydu görüntüleri ile yapılan sınıflandırma sonucunda XGBoost (OA = 0.8905), LightGBM (OA = 0.8956) ve CatBoost (OA = 0.8956) doğruluk değerlerine ulaşmışlardır (Bui ve ark., 2021). Sentinel-2 uydusuna ait R,G,B,NIR bantlarını kullanarak, buğday, mısır, pirinç, ayçiçeği, orman ve su sınıflarını içeren obje ve piksel tabanlı sınıflandırma çalışması yapmışlardır. 3 farklı test bölgesinde zaman ağırlıklı dinamik zaman çarpıtma (TWDTW) algoritması ile yapılan sınıflandırma sonucunda, obje tabanlı sınıflandırmanın (%92.62), piksel tabanlı (%90.14) sınıflandırmaya kıyasla daha yüksek doğruluk verdiği sonucuna ulaşılmıştır. Ayrıca Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) indeksinin sınıflandırma çalışmasında girdi veri olarak kullanıldığında doğruluk değerini arttırdığından bahsetmişlerdir (Belgiu & Csillik, 2018).

2. Çalışma Alanı ve Materyaller

2.1 Çalışma alanı

Çalışma alanı Eskişehir İli, Seyitgazi ve Sivrihisar İlçe sınırları içerisinde, 1996 yılında kurulmuş Battalgazi Sulama Birliği sınırlarını kapsamaktadır. Yaklaşık 20.000 hektarlık alanı kapsayan alan içerisinde, ayçiçeği, mısır, şekerpancarı, yonca gibi sulu tarım ürünleri yoğun olarak ekilmekte olup, bunlarla birlikte hububat (buğday ve arpa) ekimi ile nadasa bırakma işlemi uygulanmaktadır. Bölgede son yıllarda iklim değişikliği kaynaklı aşırı kuraklık yaşanması sebebiyle birliği besleyen baraj gölündeki seviye gittikçe azalmış, bu nedenle şahsa özel açılan kuyular ile tarımsal sulama yapıldığı bilgisine ulaşılmıştır.



Şekil 1. Çalışma alanı.

2.2 Sentinel-2 uydu görüntüleri

Sentinel-2 uyduları, Sentinel2A–Sentinel2B olmak üzere, 5 günlük zamansal çözünürlüğe, farklı bantlara sahip üç farklı konumsal çözünürlüğe (10m, 20m ve 60m) ve 13 spektral banda sahip olup, L1C ve L2A olmak üzere iki farklı formatta üretilmektedir (Sentinel Online, 2022). Bu çalışmada

atmosfer üstü yansıtım değerlerinin atmosfer altı yansıtım değerlerine dönüştürüldüğü, bitki örtüsü izleme, sulama yönetimi, arazi ve ürün desen sınıflandırması gibi uygulamalarda daha sağlıklı sonuçlar veren L2A görüntüleri kullanılmıştır. Sentinel-2 uydusunun 5 günlük çekim sıklığı ve çok sayıdaki spektral bandı, tarımsal ürünlerin izlenmesi, gözlemlenmesi ve ürün çeşidinin belirlenmesinde büyük avantaj sağlamaktadır. Bu çalışmada 2022 yılına ait 18 farklı tarihte çekilen görüntüler ile bu görüntülerden oluşturulan indeksler sınıflandırma çalışmasında kullanılmıştır.

Çizelge 1. Sentinel-2 uydusuna ait spektral bantlar

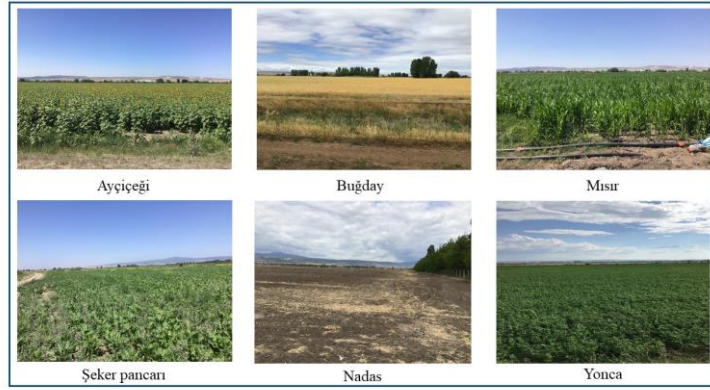
Bant adı	Dalga boyu (nm)	Mekânsal çözünürlük
Aerosol (B1)	458-523	60
Blue (B2)	458-523	10
Green (B3)	543-578	10
Red (B4)	650-680	10
Red-Edge-1 (B5)	698-713	20
Red-Edge-2 (B6)	733-748	20
Red-Edge-3 (B7)	773-793	20
NIR (B8)	785-900	10
NIRn (B9)	885-875	10
Water vapour (B10)	935-955	60
SWIR Cirrus (B11)	1360-1390	60
SWIR-1 (B12)	1565-1655	20
SWIR-2 (B13)	2100-2280	20

Çizelge 2. Sentinel-2 uydu görüntü tarihleri

Edinim tarihi	
20.02.2022	25.07.2022
27.03.2022	04.08.2022
14.04.2022	14.08.2022
29.04.2022	29.08.2022
21.05.2022	29.08.2022
31.05.2022	08.09.2022
20.06.2022	18.09.2022
03.07.2022	07.10.2022
15.07.2022	22.10.2022


2.3 Yer doğruluk verisi (arazi çalışması)

Sulama birliği ile yapılan görüşme neticesinde çalışma alanının %95'ini yonca, mısır, şekerpancarı, ayçiçeği, buğday ve nadasa bırakılmış arazilerin oluşturduğu bilgisi alınmıştır. Çalışma kapsamında birlik personeline eğitim verilmiş ve 2022 yılı temmuz ayının ilk haftasında 384 farklı lokasyondan arazide veri toplanmıştır. Toplanan veriler Tarım ve Orman Bakanlığı bünyesinde bulunan tarım parselleri ile karşılaştırılmış, sahadan toplanan ürün bilgileri sınıflandırma çalışmasında referans (eğitim-test verisi) olarak kullanılacak parsellere aktarılmıştır.



Şekil 2. Arazi çalışmasında toplanan tarımsal ürünlere ait fotoğraflar.

3. Yöntem



Şekil 3. Sınıflandırma çalışması iş akış diyagramı.

Çalışmada uygulanan yöntem adımlarını özetleyen iş akışı Şekil 3’de gösterilmiştir. Yöntem uydu görüntüsü işleme, arazi çalışması, tarım parselleri ile eğitim-test verisinin hazırlanması, hızlandırılmış makine öğrenme algoritmaları ile parsel tabanlı sınıflandırma ve doğruluk analizi işlemlerinden oluşmaktadır. İlk olarak Sentinel-2 görüntülerine ait ön işleme adımları uygulanmış,

sınıflandırma çalışmasında kullanılan bantlar ve indeksler belirlenmiştir. Araziden toplanan her ürüne ait çok zamanlı NDVI görüntüleri kullanılarak ürünlere ait spektral ayrılma eğrileri oluşturulmuş ve araziden toplanan verilerin doğruluğu kontrol edilmiştir. Çalışmada nesne tabanlı olarak kullanılacak tarım parselleri ise ürün ekim sınırlarına göre kontrol edilmiş ve gereken parsellerde uydu görüntüleri yardımıyla düzenleme/bölme işlemi uygulanmıştır. Bu işlemler sonrasında obje tabanlı makine öğrenme algoritmaları ile sınıflandırma işlemi yapılmış olup, son olarak sonuçların doğruluk analizleri hesaplanmıştır.

3.1 Uydu görüntüsü işleme

Sınıflandırma çalışmasında temin edilen görüntüler Level 2A formatında olup atmosfer altı yansıtım değerlerine sahiptir. Atmosferik etkilerden kaynaklanan bulutlar ve bulut kaynaklı gölgeler, görüntü analizlerinde başlıca gürültü kaynaklarıdır. Bulutların ve gölgelerin neden olduğu parlaklık, veri analizini olumsuz etkilemekte ve bu etkiler spektral bantlar ile bantlardan oluşturulan indeks değerlerinde değişikliklere yol açarak çeşitli analiz ve sınıflandırma işlemlerinde doğruluğu düşürmektedir (Zhu & Woodcock, 2012).

Bulutlu alanlar ile bulutların oluşturduğu gölgeler görüntü bantlarında ve bu bantlardan oluşturulan indekslerin piksel değerlerinde anomalilere neden olmakta ve sınıflandırma sonuçlarını olumsuz etkilemektedir (Zhu & Woodcock, 2012) Bu durumu ortadan kaldırmak için Avrupa Uzay Ajansı (ESA) tarafından geliştirilmiş SNAP yazılımının Sen2Core eklentisi kullanılmıştır. Sen2Core eklentisi içerisindeki The Scene Classification (SCL) algoritması kullanılarak bulutlar ve bulutların neden olduğu gölge alanlar tespit edilmiş ve bu alanlar maskelenerek sınıflandırma çalışmasına dahil edilmemiştir.

Sınıflandırma çalışmasında B2 (mavi), B3 (yeşil), B4 (kırmızı) ve B8(yakın kızıl ötesi) bantları kullanılmış ve bu bantlar kullanılarak her bir görüntüye ait NDVI indeksleri oluşturulmuştur. NDVI indeksi bitkilerin fenolojik gelişim ve değişimleri hakkında bilgi vermektedir (Zhang ve ark., 2020). Çok zamanlı görüntülerden oluşturulan NDVI indeksleri ile tarımsal ürünlerin fenolojik dönemleri belirlenip izlenebilmesine rağmen, tek zamanlı NDVI görüntülerle fenolojik dönem tespiti mümkün değildir (Viana ve ark., 2019). Sınıflandırma çalışmasında 18 farklı tarihteki R, G, B, NIR ve NDVI bantları kullanılarak toplamda 90 farklı özellik içeren görüntü yığını tarım parselleri ile karşılaştırılarak obje tabanlı sınıflandırma çalışmasında kullanılmıştır.




Şekil 4. Bulut ve bulut kaynaklı gölgelerin maskelenmiş görüntüsü.

3.2 Yersel referans veriler ve tarım parselleri


Çalışma alanının % 95'i mısır, ayçiçeği, buğday-arpa, yonca ve şekerpancarı ürünleri ile nadasa bırakılmış alanlardan oluşmaktadır. Çalışmada buğday, arpa ve tritikale ürünleri buğday sınıfı altında toplanmıştır. Sınıflandırılacak ürünlere ait araziden 384 adet nokta toplanmış olup, araziden toplanan noktalar ile tarım parselleri karşılaştırılmış, çakışan parsellere araziden toplanan ürün bilgisi yazdırılmıştır. Her bir ürünün fenolojik dönem değişimlerinin belirlenmesi, spektral ayrılma eğrilerinin oluşturulması ve arazi de toplanan verilerin kontrol edilmesi amacıyla da çok zamanlı NDVI görüntüleri kullanılmıştır.

Arazi örtüsü değişimi/geçisi, komşu parsellerdeki farklı ürün çeşidi, parsel sınırlarını belirleyen ağaçlar ve duvarlar ile parsel kenarında bulunan kadastro yolu ya da asfalt yolları içeren piksellerin, tarım parselleri ile karşılaştırılması sonucu anomaliye sebebiyet vermemesi için referans veri olarak kullanılacak tarım parsellerine negatif buffer (-10m) işlemi uygulanmıştır. Bu işlem sonrasında her bir referans parselin içerisine çok zamanlı NDVI değerleri median olarak yazdırılarak, ürünlerin spektral ayrılma eğrileri oluşturulmuştur. Oluşturulan bu spektral ayrılma eğrileri ile ürünlerin bir tarım takvimi yılında fenolojik değişimleri gözlemlenmiş olup, ayrıca sınıflandırma çalışmasında kullanılacak ve ürünlerin birbirinden ayırt edilmesini sağlayacak spesifik tarihlerin de belirlenmesi amaçlanmıştır.

Araziden toplanan veriler, oluşturulan spektral ayrılma eğrileri kullanılarak kontrol edilmiştir. Hatalı toplanan yada yanlış isimde kaydedilen ürünler spektral olarak arazide bulunduğu tarih aralığında kendi ürün türünün spesifik yansıma değerini vermemiş ise silinmiş ve sınıflandırma çalışmasına dahil edilmemiştir. Toplanan veriler referans yansıma eğrisi ile aynı ve benzer yansıma göstermiş ise çalışma içerisinde tutulmuştur. Ayrıca her bir parsel için oluşturulan spektral ayrılma eğrileri, İlçe Tarım Müdürlüğünden temin edilen ürünlere ait fenolojik takvim bilgisi ile de karşılaştırılmış ve kontrol edilmiştir.



Şekil 5. Ürünlere ait fenolojik takvim.



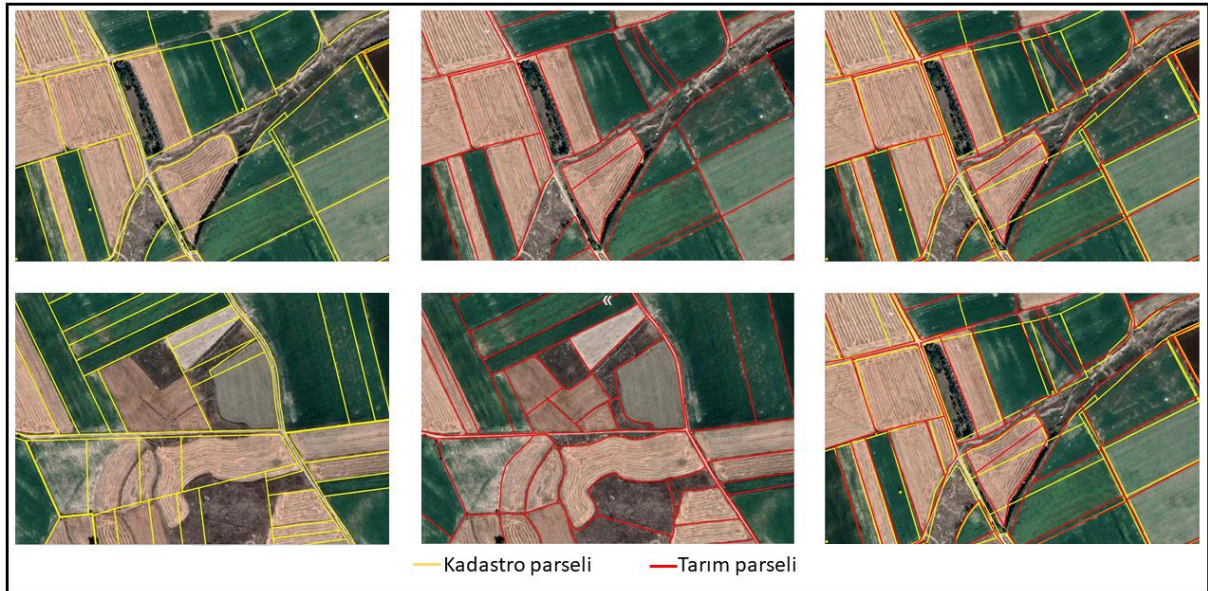
Şekil 6. Araziden toplanan tarımsal ürünlerin NDVI değerlerine göre zamansal değişimi.

Çok zamanlı NDVI görüntüleri ile oluşturulan ürünlere ait spektral ayrılma eğrileri kullanılarak araziden toplanan veriler kontrol edilmiştir. Araziden toplanan 384 adet veriden, verinin yanlış konumdan alındığı ya da yanlış isimle kaydedildiği düşünülen 36 tanesine kendi ürün türünün referans yansıma eğrisi ile aynı ve benzer yansıma değeri vermediğinden elemine edilmiştir. Sınıflandırma çalışması için çok yüksek sayıda yer doğruluk verisi bulunmadığından ve oluşacak modellerin optimum öğrenme kapasitesine erişmesini sağlamak amacı ile 348 adet verinin %60 eğitim %40'ı ise test verisi olacak şekilde seçilmiştir.

Çizelge 3. Sentinel-2 uydusuna ait spektral bantlar

Ürün	Eğitim Verisi	Test Verisi
Yonca	39	28
Nadas	20	15
Mısır	32	23
Şeker pancarı	36	22
Ayçiçeği	38	23
Buğday	43	29
TOPLAM	208	140


Tarım ve Orman Bakanlığı, Tarım Reformu Genel Müdürlüğü tarafından Tarımsal Üretim Kayıt Sistemi (TÜKAS) projesi kapsamında, ortofoto ve uydu görüntüleri üzerinden kadastro parcel sınırları içerisinde kalan ve tarım amaçlı kullanılan tarım alanları ile tarım alanı olabilecek potansiyeldeki alanlar sayısallaştırılarak tarım parselleri çizilmiş ve tarım parseli kavramını almıştır. Ayrıca parsel içerisinde bulunan ev, ahır, metruk yapı, havuz, taşlık vb. alanlar çıkartılarak salt tarım parselleri oluşturulmuştur. 2013 yılında günümüze tarım parselleri Çiftçi Kayıt Sistemi (ÇKS) başvurularında, kayıtlarında ve tarımsal desteklemelerde kullanılmaktadır. Çalışmada obje (parsel) tabanlı olarak oluşturulan bu tarım parselleri kullanılmıştır.



Şekil 7. Kadastro parselleri ile tarım parsellerinin uydu görüntüsü üzerinde görünümü.

Tarım parselleri uydu görüntüleri ile karşılaştırıldığında, bir tarım parselinin içerisinde birden fazla farklı ürün çeşidi olabildiği gibi, parselin tamamını ya da belirli bir kısmını kapsayan ekimi de yapılmaktadır. Oluşturulan tarım parselleri, salt tarım amaçlı kullanılan alanları temsil etmesine rağmen, dinamik bir yapı olan ve her üretim sezonu değişebilen tarımsal ekim ve üretim yapılan sınırlara karşılık gelmeyebilmektedir.

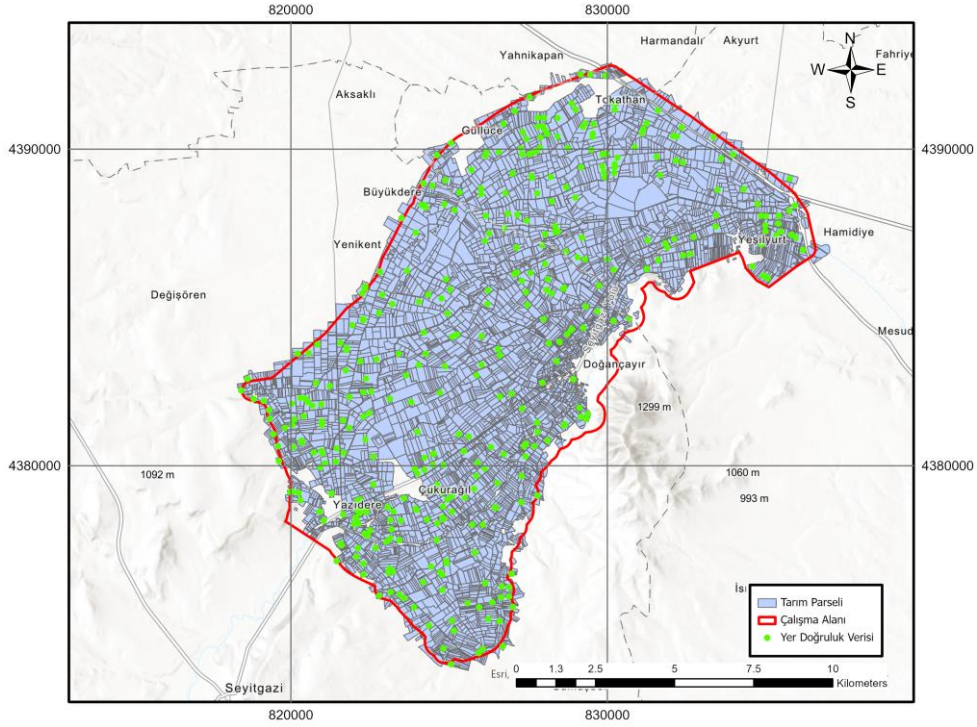
Söz konusu bu durumdan dolayı ekim yapılan sınırların tarım parselleri kullanılarak belirlenmesi amacıyla, güncel ve ideal çözünürlükte uydu görüntüsü temin edilmesi gerekmektedir. Sentinel-2 görüntüleri R-G-B-NIR bantlarında 10 metre mekânsal çözünürlükte olmakla beraber özellikle küçük parsellerde üretim yapılan sınırların belirlenmesinde düşük çözünürlükte kalmakla beraber aynı zamanda parsel sınırlarındaki, ağaçlar, kadastro yolları, binalar, taş duvarlar ve çalılıkları kapsayan farklı arazi örtülerine ait pikselleri de içerebilmektedir. Çok yüksek çözünürlüklü metre altı görüntüler ile tarımsal ekim yapılan alanlar kolaylıkla belirlenebilmesine rağmen, bu görüntüler çok maliyetli olması ve istenilen tarih aralığındaki çekim talebinin karşılanamaması sebebiyle alternatif uydu arayışına gidilmiştir. Çalışmada 3 metre mekânsal çözünürlüğe sahip 4 bantlı (R-G-B-NIR) , günlük çekim yapabilen Planet Scope uydusu kullanılmıştır. Planet eğitim ve araştırma programı ile öğrencilere, araştırmacılara ve akademisyenlere aylık 5000km²'lik alana kadar ücretsiz uydu görüntüsü sağlamaktadır (Planet, 2023). Çok zamanlı NDVI görüntülerinden oluşturulan spektral ayrılma eğrileri incelendiğinde, kışlık ürün olan buğdayın en yüksek yansımaya yaptığı tarihin mayıs ayının 3. haftası, yazlık ürünlerin birbirinden farklı yansımaya özelliği gösterdiği tarihin ise ağustosun 3. haftası olduğu gözlemlenmiştir. Bu sebeple 20.05.2022 ve 22.08.2022 tarihlerine ait iki farklı Planet Scope görüntüsü temin edilerek tarım parselleri ile karşılaştırılmış ve ekim yapılan alanlar ile farklı ürün ekiminden ve zamanında kaynaklı, yansımaya farklılıklarından ortaya çıkan sınırlar manuel olarak editlenerek belirlenmiştir. Şekil8a'da 2 adet tarım parseli bulunması rağmen Planet Scope görüntüsü ile tarım parselleri karşılaştırılıp, tarımsal üretim yansımaları olan alanlar bölündüğünde tarım parseli sayısının Şekil 8b'de 5'e çıktığı görülmektedir.



Şekil 8. a) Tarım parsellerinin görünümü b) Tarım parselinin Planet Scope görüntüsü kullanılarak oluşturulmuş görüntüsü.

İki farklı tarihteki Planet Scope görüntüleri kullanılarak, ekim yapılan alanlar ile farklı ürün ekiminden kaynaklı yansımaya farklılıklarından ortaya çıkan sınırların oluşturulması ile tarım parselleri düzenlenerek çizilmiştir. Sınıflandırma çalışmasında, sınıflandırılacak ürünler sadece ekili ürünler olmakla beraber çalışma alanında dikili ürünler de (meyve ağacı, kavak, zeytin ağaçları) bulunmaktadır. Sınıflandırma çalışmasına dâhil olmayan bu ürünleri içeren parsellerin çalışmadan çıkarılması gerekmekte olup Sentinel-2 ve Planet Scope görüntüleri ile dikili alanlara ait parselleri belirlenmesi mümkün değildir.

Tarım Reformu Genel Müdürlüğü tarafından Arazi Parsel Tanımlama Sistemi (LPIS) projesi kapsamında arazi örtüsü ve kullanım sınıfları oluşturulmuş. 24 farklı sınıf içeren fiziksel bloklar içerisinde, T0-sürekli ağaçlık alanlar, T1-zeytin ağaçları, sınıflarına ait poligonlar ile tarım parselleri karşılaştırılarak, dikili alanlara ait parseller elemine edilmiştir. Düzenlenme ve silme işlemleri sonucunda çalışma alanı içerisinde 6443 adet tarım parseli oluşturulmuştur. Sentinel-2 görüntüleri ile oluşturulan tarım parselleri karşılaştırılarak parsel sınırında kalan piksellerin anomaliye neden olmaması için, tarım parseli üzerinde -10 metre buffer işlemi uygulanmış olup, her bir poligona 18 farklı tarihteki R-G-B-NIR bantları ile NDVI indeks değerleri aktarılmıştır.



Şekil 9. Çalışma alanı içerisinde bulunan tarım parsellerinin görünümü.

3.3 Hızlandırılmış makine öğrenmesi algoritmaları ile sınıflandırma

Çalışmada hızlandırılmış (Boosting) makine öğrenmesi algoritmalarından; gradyan artırma (GBM), aşırı gradyan artırma (XGBoost), kategorik artırma algoritması (CatBoost) ve hafif gradyan artırma (LightGBM) makine öğrenme algoritmaları kullanılmıştır.

3.3.1 Gradyan artırma algoritması (GBM)

GBM, zayıf öğrencileri (weak learner) bir araya getirerek güçlü bir öğrenici (strong learner) oluşturmayı amaçlayan, bir başka deyişle her entegrasyonda önceki iterasyonların hata oranlarını düzelterek çalışan özellikle sınıflandırma ve regresyon problemleri için kullanılan bir makine öğrenme algoritmasıdır (Natekin & Knoll, 2013). Gradient Boosting Machine, karmaşık veri setlerinde ve veri setinde çok sayıda öznelik bulunması durumlarında yüksek tahmin performansı elde elden için oldukça etkili bir algoritmadır (Jafarzadeh ve ark., 2021). GBM, popüler uygulamalardan biri olan XGBoost, LightGBM ve CatBoost gibi çeşitli algoritmalara da ilham kaynağı olmuştur.

3.3.2 Aşırı gradyan artırma algoritması (XGBoost)

XGBoost büyük ölçekli verileri işleyebilen ve hesaplamaları paralelleştirebilen, gradyan artırma makineleri (GBM) algoritmasının daha gelişmiş bir versiyonudur (Chen & Guestrin, 2016). Algoritma ağaç yapısını artırıp, adım adım öğrenerek hata oranını minimize eden ölçeklenebilir bir makine öğrenme algoritmasıdır (Farid ve ark., 2013). XGBoost değişkeni tahmin etmek için bir dizi karar oluşturur ve her ağaç önceki ağaçların tahmin hatalarını azaltmak için tasarlanmıştır (Mitchell & Frank, 2017). Algoritma farklı düzenleme tekniği kullanarak ağaçların karmaşıklığını kontrol ederek daha yüksek ve bir performans sergilemektedir (Patrous, 2018). XGBoost aşırı öğrenmeyi ve aşırı uyumluluğu önlemek için, ağaçların derinliği sınırlama, ağaç yapısını basitleştirme ve değişkenlerin önemini belirleme gibi teknikler kullanmaktadır.

3.3.3 Hafif gradyan artırma algoritması (LightGBM)

LightGBM, Microsoft DMTK (Distributed Machine Learning Toolkit) projesi kapsamında 2017 yılında geliştirilmiş, karar ağacı algoritmalarına dayanan bir boosting algoritması olup, XGBoost'un

eğitim performansını artırmaya yönelik geliştirilen bir GBM türüdür (VBO, 2023). Verinin eğitilmesi aşamasında LightGBM yapraklar arasında yatay olarak dallanarak genişlemekte, böylelikle daha az hata oranına sahip ve daha hızlı öğrenme gerçekleştirilmektedir (Ke ve ark., 2017; Li ve ark., 2019). LightGBM bünyesinde gradyan tabanlı tek taraflı örnekleme (Gradient-based One-Side Sampling, GOSS) ve ayrıcalıklı öznelik desteleme (Exclusive Feature Bundling, EFB) algoritmasını bulundurmakta olup, bu algoritmalar işlem hızını artırmaktadır (Üstüner ve ark., 2020). Özellikle büyük veri setleri, yüksek boyutlu özellik uzayları ve yüksek hızlı tahminler gerektiren uygulamalarda tercih edilmektedir.

3.3.4 Kategorik attırma algoritması (CatBoost)

CatBoost algoritması 2017 yılında Yandex firması tarafından geliştirilen ve gradyan attırma tekniğini kullanan, hızlı eğitim süresine sahip ve yüksek performansı ile bilinen bir GBM algoritmasıdır (Medium, 2023). CatBoost ardışık olarak ağaçları birleştirerek, bir önceki ağacın hatalarını gidermeye çalışır, böylelikle modelin genel hata oranını azaltarak tahmin performansını artırmaktadır (Patrous, 2018). GBM yöntemini kullanan CatBoost nedenle birçok ağaç (decision tree) ve bunları birleştirerek tahminler yapar. Ancak CatBoost, kategorik değişkenleri doğrudan işleyebilir ve bu değişkenlerin etkisini daha iyi yakalayabilmektedir, ayrıca, overfitting (aşırı uydurma) sorunlarına karşı dirençlidir ve daha az hiper parametre ayarı gerektirmekte olup bu nedenle kullanımı kolaydır (İbrahim ve ark., 2020).

Çizelge 4. Algoritmalara ait avantajlar ve dezavantajlar


ALGORİTMA	AVANTAJLARI	DEZAVANTAJLARI
GBM	<ul style="list-style-type: none">• Model kompleksliği• Overfitting direnci• Özellik seçimi• Veri tipi esnekliği	<ul style="list-style-type: none">• Eğitim süresi• Aşırı öğrenme• Veri ön işleme gereksinimi• Veri kümesi sorunsalı
XGBoost	<ul style="list-style-type: none">• Paralel ağaç yapısı• Ön bellek farkındalığı• Çekirdek dışı hesaplama• Aşırı uyumdan kaçınma• Çapraz doğrulama	<ul style="list-style-type: none">• Zaman alıcı hesaplama• Aşırı öğrenme riski• Hiper parametrelere duyarlılık• Yüksek bellek kullanımı• Karmaşık algoritma
LightGBM	<ul style="list-style-type: none">• Parametre optimizasyonu• Paralel öğrenme• Yüksek tahmin oranı• Parametre optimizasyonu• Yüksek işlem hızı	<ul style="list-style-type: none">• Karmaşık algoritma• Hiper parametrelere duyarlılık• Yüksek bellek kullanımı• Eksik değer işleme• Sınıf dengesizliği
CatBoost	<ul style="list-style-type: none">• Kategorik değişken desteği• Parametre optimizasyonu• Yüksek işlem hızı• Aşırı öğrenme direnci• Yüksek tahmin oranı	<ul style="list-style-type: none">• Bellek ayak izi• Hiper parametre ayarı• Belirli dil bağılılığı (python)• Yorumlanabilirlik• Veri ön işleme

Hiper parametre, makine öğrenme algoritmalarında algoritmanın performansını ve başarısını etkileyen, modelin kendisi tarafından öğrenilmeyen kullanıcı tarafından belirlenen modele ait özel parametrelerdir. Makine öğrenme algoritması ile yapılacak bir çalışmada, veri setinin özelliği, verinin büyüklüğü ve diğer değişkenler göz önünde bulundurularak, başarı metriğine göre en uygun parametre kombinasyonunu bulma işlemine hiper parametre optimizasyonu olarak adlandırılmaktadır (Kuş ve ark., 2021). Hiper parametre optimizasyonu, doğru hiper parametre değerlerini seçmek için farklı stratejiler ve yöntemler kullanarak modelin performansını en üst düzeye çıkararak aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) durumlarının önüne geçmeyi hedefler (Maxwell ve ark., 2018). Makine öğrenme algoritmalarında en iyi sonucu veren hiper parametreleri bulmaya yönelik çeşitli yöntemler kullanılmaktadır. hiper parametrelerinin ayarlanması için grid search ve random search olmak üzere iki farklı yöntem kullanılmaktadır. Grid search yöntemi, belirli bir parametre aralığını seçerek tüm olası kombinasyonları deneyerek en iyi parametre değerini bulurken, random search yöntemi, belirli bir parametre aralığından rastgele örneklem olarak parametre değerlerini belirlemektedir (Escabias, 2017). Parametreler, boosting algoritmaları arasında farklılık gösterse de, birçok boosting algoritmasının ortak parametreleri bulunmaktadır. Bu çalışmada Grid search yöntemi ile hızlandırılmış makine öğrenmelere algoritmalarına ait parametreler ve modelin en iyi sonucu verdiği parametre değerleri Çizelge 5’de yer almaktadır.

Çizelge 5. Algoritmalara ait hiper parametre değerleri

Hiper parametreler	Algoritma			
	GBM	XGBoost	LightGBM	CatBoost
Number of trees (Ağaç sayısı)	110	175	125	100
Learning rate (Öğrenme oranı)	0.5	0.3	0.1	0.1
Max depth (Ağaçların maksimum derinliği)	8	10	5	12
Min samples leaf (Minimum örnek sayısı)	5	12	20	17
Subsample (Örnekleme sayısı)	0.8	1	0.9	1

Hızlandırılmış makine öğrenme algoritmaları ve arazi gerçeği verileri kullanılarak obje (tarım parseli) tabanlı ürün desen sınıflandırması yapılmış ve elde edilen sonuçlar karşılaştırılmıştır.



Şekil 10. Hızlandırılmış makine öğrenme algoritmaları ile yapılan parsel tabanlı sınıflandırma.

4. Bulgular

Sınıflandırma çalışması sonucunda her bir sınıfa ait precision (hassasiyet), recall (duyarlılık) ve F1 Skor (kesinlik değerleri) ile genel doğruluk, Cohen's Kappa katsayısı değerleri hesaplanmıştır.

Recall: Pozitif durumların ne kadar başarılı tahmin edildiğini gösterir.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

Precision: Pozitif olarak tahmin edilen bir durumdaki başarıyı gösteren durumdur.

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

F1-Score: Kesinlik (precision) ve duyarlılık (recall) değerlerinin harmonik ortalamasıdır.

$$\text{F1-Score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

Genel Doğruluk (Accuracy): Oluşturulan bir modelde doğru olarak yapılan tahminlerin tüm tahminlere oranıdır.

Çizelge 6. Sınıflandırma sonucunda her bir algoritma için doğruluk değerleri

SINIFLAR	GBM			XGBoost		
	F1	Recall(%)	Precision (%)	F1	Recall (%)	Precision (%)
Yonca	95.8	96.4	95.2	95.5	96.2	94.8
Nadas	94.0	94.2	93.9	93.7	93	94.5
Mısır	89.9	90.3	89.6	89.7	89.2	90.2
Şeker pancarı	88.6	88.8	88.5	88.8	88.5	89.1
Ayçiçeği	92.9	93.3	92.5	92.9	92.4	93.5
Buğday	92.2	92.2	92.3	92.2	92.5	91.9
Genel doğruluk	90.30%			%91.1		
Kappa katsayısı	0.90			0.90		

SINIFLAR	LightGBM			CatBoost		
	F1	Recall(%)	Precision (%)	F1	Recall (%)	Precision (%)
Yonca	97.8	98.1	97.5	97.4	98.4	96.5
Nadas	93.9	94.2	93.7	95.2	95.6	94.8
Mısır	90.3	89.4	91.3	88.9	90.5	87.3
Şeker pancarı	89.2	89.2	89.3	89.2	89.2	89.3
Ayçiçeği	93.4	94.3	92.5	92.6	92.8	92.5
Buğday	92.5	91.8	93.2	92.8	92.1	93.6
Genel doğruluk	93.90%			93.50%		
Kappa katsayısı	0.93			0.93		

Çizelge 6'da verilen doğruluk değerlerine göre sınıflandırma sonucunda LightGBM algoritması ile CatBoost algoritmaları birbirlerine çok yakın skorlarla en yüksek değeri vermiş olup, bu algoritmaları XGBoost ile GBM algoritmaları takip etmiştir. 18 farklı tarihteki R,G,B,NIR ve bu bantlarından üretilen NDVI indekslerine ait bantlarla toplamda 90 farklı özelliğin kullanıldığı sınıflandırma çalışmasında en düşük doğruluk değeri veren algoritma ile (GBM - %90.3) en yüksek doğruluk değerine sahip algoritma

(LightGBM - %93.9) arasında yaklaşık %3.5 fark bulunmaktadır. Hızlandırılmış makine öğrenme algoritmaları ile yapılan sınıflandırma sonucunda tüm sınıfların ve genel doğruluk değerinin neredeyse % 90 üzerinde skor vermesi sınıflandırma çalışmasının başarılı ve istenilen düzeyde olduğunu göstermektedir. Her bir sınıf için doğruluk değerleri incelendiğinde tüm algoritmalarda yonca ve nadas sınıfları en yüksek doğruluk değerini vermektedir. Sınıflandırma çalışmasında mısır ve şeker pancarı sınıfları ise birbirleri ile bir miktarda karışmış olup en düşük sınıflandırma sonucunu veren sınıflardır. Mısır ve şeker pancarı ürünlerinin Şekil 5’de görüldüğü üzere benzer fenolojik evreleri içermesinin yanı sıra çok zamanlı NDVI görüntülerinden oluşturulan spektral ayrılma eğri karakteristiklerinin (Şekil 6) yakın olması, ürünlerin yıl içerisinde benzer yansıma yaptıklarının göstergesidir. Söz konusu bu durumdan dolayı sınıflar birbirleri ile bir miktar karışmış olup doğruluk değerinin düşmesine sebep olmuştur. Ayrıca bazı parsellerde sağlıklı olarak gelişmemiş buğday sınıfı ile nadas sınıfının az da olsa birbirleri ile karıştığı tespit edilmiştir. Her bir sınıf ve algoritma için oluşturulan hata matrislerinde de (Şekil 10) söz konusu bu durumlar gözükmemektedir.

		GBM						XGBoost					
Yonca	0.96	0.00	0.01	0.01	0.02	0.00	Yonca	0.96	0.00	0.01	0.01	0.02	0.00
Nadas	0.01	0.94	0.01	0.00	0.02	0.02	Nadas	0.01	0.94	0.01	0.00	0.02	0.02
Mısır	0.00	0.00	0.90	0.08	0.02	0.00	Mısır	0.00	0.00	0.90	0.08	0.02	0.00
Ş. Pancarı	0.00	0.00	0.09	0.89	0.02	0.00	Ş. Pancarı	0.00	0.00	0.09	0.89	0.02	0.00
Ayçiçeği	0.00	0.00	0.03	0.03	0.94	0.00	Ayçiçeği	0.00	0.00	0.03	0.03	0.94	0.00
Buğday	0.01	0.01	0.02	0.01	0.02	0.93	Buğday	0.01	0.01	0.02	0.01	0.02	0.93
	Yonca	Nadas	Mısır	Ş. Pancarı	Ayçiçeği	Buğday		Yonca	Nadas	Mısır	Ş. Pancarı	Ayçiçeği	Buğday

		LightGBM						CatBoost					
Yonca	0.98	0.00	0.01	0.01	0.00	0.00	Yonca	0.97	0.00	0.02	0.01	0.00	0.00
Nadas	0.02	0.93	0.02	0.00	0.01	0.02	Nadas	0.01	0.95	0.01	0.00	0.01	0.02
Mısır	0.00	0.00	0.90	0.10	0.00	0.00	Mısır	0.01	0.00	0.89	0.80	0.02	0.00
Ş. Pancarı	0.00	0.00	0.10	0.90	0.00	0.00	Ş. Pancarı	0.00	0.00	8.00	0.90	0.02	0.00
Ayçiçeği	0.00	0.00	0.03	0.03	0.94	0.00	Ayçiçeği	0.00	0.00	0.03	0.04	0.93	0.00
Buğday	0.01	0.01	0.02	0.01	0.02	0.93	Buğday	0.01	0.01	0.02	0.01	0.03	0.92
	Yonca	Nadas	Mısır	Ş. Pancarı	Ayçiçeği	Buğday		Yonca	Nadas	Mısır	Ş. Pancarı	Ayçiçeği	Buğday

Şekil 10. Sınıflandırma sonuçlarına ait hata matrisleri.

5. Tartışma ve Sonuç

Bu çalışma, Eskişehir İli, Seyitgazi ve Sivrihisar İlçeleri arasında kalan Battalgazi Sulama Birliği sınırları içerisinde bulunan, 2022 yılına ait 18 farklı tarihteki Sentinel-2 uydu görüntüleri ile R yazılımı ortamında hızlandırılmış makine öğrenme algoritmaları kullanılarak obje (tarım parseli) tabanlı sınıflandırma yöntemi ile yapılmıştır. Çalışmada her bir tarihteki Sentinel-2 görüntüsü için 4 band (R-G-B-NIR) ve bu bantlardan üretilen NDVI indeksleri olmak üzere toplamda 80 bant sınıflandırma

çalışmasında kullanılmıştır.

Sınıflandırma çalışmasında sınıflandırılan ürünler için saha çalışması yapılmış olup, araziden ürün bilgisi içeren 384 adet nokta toplanmıştır. Her bir ürünün fenolojik dönem değişimlerinin belirlenmesi, spektral ayrılma eğrilerinin oluşturulması ve arazi de toplanan verilerin kontrol edilmesi amacıyla da çok zamanlı NDVI görüntüleri kullanılmıştır.

Tarım ve Orman Bakanlığı bünyesinde tarımsal alanları temsil eden kadastro parsellerinden tarım dışı alanlar ile yapıların çıkarılması ve kadastro olmayan alanlarda ise tarım alanlarının sayısallaştırılması ile ülke ölçeğinde tarım parselleri oluşturularak tarım parseli kavramını almıştır. Tarım parselleri 2013 yılından günümüze Çiftçi Kayıt Sistemi (ÇKS) başvurularında aktif olarak yer almakta ve kullanılmaktadır. Bu çalışmada farklı çözünürlükteki uydu görüntüleri ile oluşturulan segmentlerin (bölütlerin) avantajları ve dezavantajları göz önüne alındığında, tarım parsellerinin sınıflandırma çalışmasında obje olarak kullanılabilirliği test edilmiştir. Çok zamanlı görüntüler, bu görüntülerden seçilen bantlar ve bantlardan oluşturulan indekslerle yapılan sınıflandırma çalışmalarında, piksel tabanlı sınıflandırmada girdi veri seti ve boyutu, nesne tabanlı sınıflandırmaya kıyasla fazla sayıda olduğundan, sınıflandırma işlemi zaman almakta ve yüksek kapasiteli makinalara ihtiyaç duyulmasına sebep olmakta olup, nesne tabanlı sınıflandırma çalışması bu kapsamda çok daha avantajlıdır.

Tarım parselleri, salt tarım amaçlı kullanılan alanları temsil etmekte olup bu çerçevede oluşturulmasına rağmen, her bir üretim sezonu tarım parsel sınırları (geometrisi) ile tarımsal üretim yapılan bir başka deyişle ekim yapılan sınırlar (geometri) her parsel için birebir uyuşmadığı, bazı parsellerde farklılıklar olduğu tespit edilmiştir. Ayrıca tarım parsel içerisinde, birden farklı üründe ekim ve tarımsal üretim yapıldığı durumlarda görülmektedir. Objeye tabanlı yapılacak tarımsal ürün desen sınıflandırmasında, ekim alanları ile farklı türde ekim yapılmasından kaynaklı sınırların tespit edilmesi gerekmektedir. Söz konusu bu durumların olduğu parsellerde tarımsal parsellerinin doğrudan obje olarak kullanılmasının mümkün olmadığı tespit edilmiştir. Bu sebeple aktif ekim yapılan alanlar yeniden düzenlenmiştir. Bu düzenleme işleminde küçük parsellerde Sentinel-2 görüntülerine ait en yüksek çözünürlüklü bantları (R-G-B-NIR- 10m) yetersiz kalacağından dolayı, 3 metre mekânsal çözünürlüklü Planet Scope görüntüleri kullanılmıştır. 2000 hektarı kapsayan bir alanda 472 adet ham tarım parselinin bölünmesi sonucu toplamda 6443 adet parsel objeye tabanlı olarak sınıflandırma çalışmasında kullanılmıştır.

Tarım parsellerinin ham olarak kullanılması ve altlık görüntüler ile düzenlenmesiyle oluşturulan bu yöntem, Sentinel-2 görüntüleri ile objeye tabanlı sınıflandırma çalışmalarında oluşturulan segmentler (bölütler) göre çok daha hassas olduğu tespit edilmiştir. Tarım parsellerinin küçük ölçekli ve orta ölçekli alanlarda uygulanan yöntem ile kullanılabilir olduğu, geniş alanlarda ise alternatif bir yöntemin geliştirilmesi gerektiği sonucuna varılmıştır. Bu çalışmanın devamı olarak Sentinel görüntüleri derin öğrenme yöntemleriyle çözünürlüğü iyileştirilerek, çeşitli segmentasyon (bölütleme) algoritmalarıyla parsel sınırları otomatik ve doğru belirlenerek objeye tabanlı sınıflandırma çalışması tekrar yapılacaktır.

Çalışmada 18 farklı tarihteki R,G,B,NIR ve NDVI bantları kullanılarak toplamda 90 farklı özellik içeren görüntü yığını ve tarım parselleri ile hızlandırılmış makine öğrenme algoritmaları kullanılarak sınıflandırma çalışması yapılmıştır. Her bir algoritmaya ait sınıflandırma sonucu %90 üzerinde genel doğruluk vermiş ve sınıflandırma çalışması başarılı olmuştur. Algoritmalara ait genel doğruluk değerleri karşılaştırıldığında, hem genel doğruluk hem sınıf bazında bir algoritmanın diğer algoritmadan çok üstün olmadığı sonuçların birbirine yakın olduğu görülmektedir. Her bir algoritma için çok yakın fenolojik dönemlere sahip sınıflarda (mısır ve şeker pancarı) diğer sınıflara kıyasla sınıflandırma sonucunun bir miktar düşük çıktığı sonucuna varılmıştır. Bir sonraki çalışmada yakın fenolojik dönemlere sahip sınıflar için ek bantlar, indeksler ve doku özellikleri kullanılarak, aynı ve farklı algoritmalarla sınıflandırma çalışması yapılarak sonuçlar karşılaştırılacaktır.

Kaynakça

- Antunes, A., Lingnau, C., & Centeno, J. (2003, Nisan). *Object oriented analysis and semantic network for high resolution image classification*. Anais XI SBSR, Belo Horizonte, Brazil.
- Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509-523. doi:10.1016/j.rse.2017.10.005

- Bui, Q. T., Chou, T. Y., Hoang, T. V., Fang, Y. M., Mu, C. Y., Huang, P. H., ..., & Meadows, E. M. (2021). Gradient boosting machine and object-based CNN for land cover classification. *Remote Sensing*, 13(14), 2709. doi:10.3390/rs13142709
- Chen, T. Q., & Guestrin, C. (2016, Ağustos). *XGboost: a scalable tree boosting system*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco. doi:10.1145/2939672.2939785
- Csillik, O., Belgiu, M., Asner, G. P., & Kelly, M. (2019). Object-based timeConstrained dynamic time warping classification of crops using Sentinel-2. *Remote Sensing*, 11(10), 1257. doi:10.3390/rs11101257
- Dizdaroğlu, T. (2019). *Sentinel-1 ve Sentinel-2 verilerinden tarımsal ürün sınıflandırması için makine öğrenme algoritmalarının karşılaştırılması*. (Yüksek lisans tezi), Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Escabias, C. B. (2017). *Tree boosting data competitions with XGBoost*. (MSc), Universitat Politècnica de Catalunya Facultat de Matemàtiques i Estadística.
- Farid, D. M., Maruf, G. M., & Rahman, C. M. (2013, Ağustos). *A new approach of boosting using decision tree classifier for classifying noisy data*. 2013 International Conference on Informatics, Electronics and Vision (ICIEV), Dhaka, Bangladesh. doi:10.1109/ICIEV.2013.6572718
- Ibrahim, A. A., Ridwan, L. R., Muhammed, M. M., Abdulaziz, R. O., & Saheed, G. A. (2020). Comparison of the catboost classifier with other machine learning methods. *International Journal of Advanced Computer Science and Applications*, 11(11), 738-748. doi:10.14569/IJACSA.2020.0111190
- Jafarzadeh, H., Mahdianpari, M., Gill, E., Mohammadimanesh, F., & Homayouni, S. (2021). Bagging and boosting ensemble classifiers for classification of multispectral, hyperspectral and polsar data: a comparative evaluation. *Remote Sensing*, 13(21), 4405. doi:10.3390/rs13214405
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. Y. (2017). *Lightgbm: A highly efficient gradient boosting decision tree*. Advances in Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA.
- Kuş, İ., Keser, S. B., & Yolaçan N. E. (2021), Saldırı tespit sistemlerinde topluluk öğrenme yöntemlerinin kıyaslanması. *European Journal of Science and Technology*, 31(1), 725-734. doi:10.31590/ejosat.971875
- Li, B. (2022). Farm parcel extraction in high resolution remote sensing image based on hierarchical spectrum and shape features. *Preprint from Research Square*, 1-16. doi:10.21203/rs.3.rs-1218962/v1
- Li, W., Ding, S., Chen, Yi., Wang, H., & Yang, S. (2019). Transfer learning-based default prediction model for consumer credit in China. *The Journal of Supercomputing*, 75, 862-884. doi:10.1007/s11227-018-2619-8
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018), Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. doi:10.1080/01431161.2018.1433343
- Medium. (2023). CatBoostClassifier ne demek ? <https://medium.com/@meltem.aydin1875/catboostclassifier-ne-demek-d5656d5f9fd9> Erişim tarihi: 20.09.2023.
- Mitchell, R., & Frank, E. (2017). Accelerating the XGBoost algorithm using GPU computing. *PeerJ Computer Science*, 3, e127. doi:10.7717/peerj-cs.127
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Front Neurorobot*, 7, 21. doi:10.3389/fnbot.2013.00021
- Patrous, Z. S. (2018). Evaluating XGBoost for user classification by using behavioral features extracted from smartphone sensors. (MSc), KTH Royal Institute of Technology, School of Computer Science and Communication, Sweden.
- Planet. (2023). Education and Research Program. <https://www.planet.com/markets/education-and-research/> Erişim tarihi: 10.08.2023.
- Safarov, F., Temurbek, K., Jamoljon, D., Temur, O., Chedkou, J. C., Abdusalomov, A. B., & Co, Y-I. (2022). Improved agricultural field segmentation in satellite imagery using TL-ResUNet architecture. *Sensor*, 22(24), 9784. doi:10.3390/s22249784

- Sentinel Online. (2022). Sentinel-2 Mission Guide <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2> Erişim tarihi: 16.08.2023.
- Tavus, B., Karataş, K., & Türker, M. (2019). Tarımsal alanlarda yüksek çözünürlüklü IKONOS uydu görüntüsünden nesne-tabanlı ürün deseni tespiti. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25(5), 603-614. doi:10.5505/pajes.2018.25428
- Üstüner, M., Abdikan, S., Bilgin, G., & Balık Şanlı, F. (2020). Hafif gradyan artırma makineleri ile tarımsal ürünlerin sınıflandırılması. *Türk Uzaktan Algılama ve CBS Dergisi*, 1(2), 97-105.
- Vajsová, B., Fasbender, D., Wirnhardt, C., Lemajic, S., & Devos, W. (2020). Assessing spatial limits of Sentinel-2 data on arable crops in the context of checks by monitoring. *Remote Sensing*, 12(14), 2195. doi:10.3390/rs12142195
- VBO. (2023). <https://www.veribilimiokulu.com/lightgbm/> Erişim tarihi: 20.06.2023.
- Viana, C. M., Girão, I., & Rocha, J. (2019). Long-term satellite image time-series for land use/land cover change detection using refined open source data in a rural region. *Remote Sensing*, 11(9), 1104. doi:10.3390/rs11091104
- Zhang, H., Kang, J., Xu, X., & Zhang, L. (2020). Accessing the temporal and spectral features in crop type mapping using multi-temporal Sentinel-2 imagery: A case study of Yi'an County, Heilongjiang Province, China. *Computers and Electronics in Agriculture*, 176(2), 105618. doi:10.1016/j.compag.2020.105618
- Zhu, Z., & Woodcock, C. E. (2012). Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83-94. doi:10.1016/j.rse.2011.10.028