

Açık kaynak kodlu Eo-learn kütüphanesi ve çok zamanlı Sentinel-2 görüntüleri ile tarımsal ürün sınıflandırması

Fatih Fehmi Şimşek^{1*}, Süleyman Savaş Durduran²

¹Tarım ve Orman Bakanlığı, Tarım Reformu Genel Müdürlüğü, Entegre İdare ve Kontrol Sistemi Daire Başkanlığı, 06800, Çankaya, Ankara, Türkiye

²Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 42090, Meram, Konya, Türkiye

Öz: Bu çalışmada, Denizli ili, Baklan, Çal ve Çivril ilçeleri sınırları arasında kalan Çivril-Baklan Ovası 'nda 2020 yılına ait tarımsal ürün desen sınıflandırması yapılmıştır. Sınıflandırma işleminde, uzaktan algılama çalışmalarında makine öğrenmesi ile derin öğrenme algoritmalarını kullanan açık kaynak kodlu Eo-Learn kütüphanesi ve çok zamanlı Sentinel-2 görüntüleri kullanılmıştır. Çalışmada referans parsel olarak Çiftçi Kayıt Sistemi'ne (ÇKS) kayıtlı parseller kullanılmış olup, ÇKS verisinin yer doğruluk verisi olarak kullanılmasından önce ön düzenleme ve kural tabanlı silme işlemleri gerçekleştirilmiştir. Hafif gradyan artırma makineleri (Light Gradient Boosting Machines, LightGBM) algoritması kullanarak hububat, mısır, şeker pancarı, ayçiçeği, haşhaş, üzüm, meyve ağacı ve yonca ürünlerini içeren tarımsal ürün desen sınıflandırması yapılmıştır. Sınıflandırma sonuçlarının değerlendirilmesinde k-katmanlı çapraz doğrulama yöntemi kullanılmış ve genel doğruluk %93.5 olarak elde edilmiştir. Sınıflandırma işlemine eğitim verisi olarak girmemiş Tarım Sigortaları Havuzu (TARSİM) parselleri ile ikinci bir doğruluk analizi yapılmış olup genel doğrulukta %91.1 kappa katsayısında 0.89 değerine ulaşılmıştır.

Anahtar Sözcükler: Eo-Learn, Sentinel-2, ÇKS, TARSİM, Sınıflandırma, Uzaktan algılama, Tarım

Agricultural crop classification with open source Eo-learn library and multi-temporal Sentinel-2 images

Abstract: In this study, agricultural crop classification for 2020 was carried out in Çivril-Baklan Plain, which is located between the borders of Denizli Province, Baklan, Çal and Çivril districts. The open-source Eo-Learn library that uses machine learning and deep learning algorithms in remote sensing studies and multi-temporal Sentinel-2 images was utilized in the classification process. In this study, the parcels registered in the Farmer Registration System (FRS) were used as reference parcels and before using FRS data as ground truth data, pre-editing and rule-based deletion processes were performed. By using Light Gradient Boosting Machines (LightGBM) algorithm, agricultural product pattern classification was carried out including cereal, maize, sugar beet, sunflower, hash, vineyard, fruit tree and clover crops. Classification results were evaluated using k-fold cross-validation with an overall accuracy of %93.5. A second accuracy assessment was performed with Agricultural Insurance Parcels (TARSİM) that were not included in the classification process as training data, achieving an overall accuracy of %91.1 and Kappa coefficient of 0.89.

Keywords: Eo-Learn, Sentinel-2, ÇKS, TARSİM, Classification, Remote sensing, Agriculture

* Sorumlu Yazar/Corresponding Author: Tel: +90 312 258 78 01 / 2050

Geliş Tarihi/Received: 24.02.2022

Kabul Tarihi/Accepted: 27.04.2022



0000-0003-4016-4408, f.fehmisimsek@gmail.com (Şimşek F.F.)*
0000-0003-0509-4037, durduran2001@gmail.com (Durduran S.Ş.)

1. Giriş

Uzaktan algılama teknolojilerindeki gelişmelere bağlı olarak, mekânsal analizlerle farklı konumsal, zamansal ve spektral çözünürlükte veri elde edilmekte olup, veriler ile mekânsal bilgiye ihtiyaç duyan pek çok bilim dalı için güvenilir ve doğru sonuçlara ulaşma imkânı sağlanmaktadır. Bu mekânsal bilgilerden biri de uzaktan algılama teknolojisinin yoğun olarak kullanıldığı arazi örtüsü, bitki örtüsü, tarımsal ürün desen tespiti ve değişimidir. Değişimler ve analizlerin tespiti yöntemlerinden biri de farklı özelliklere sahip uydu görüntüleridir. Ücretsiz olarak uydu görüntüsü elde etmek gün geçtikçe daha kolay hale gelmekte olup Copernicus programı buna iyi bir örnektir ([URL-1](#)). Bu program çerçevesinde farklı özelliklere sahip Sentinel uyduları bulunmakta olup bunlardan biri de pasif sensörlü bir uydu olan Sentinel-2 uydusudur. Sentinel-2 uydusunun zengin bant sayısı, farklı konumsal çözünürlükte görüntüler sağlaması, sık çekim aralığının olması tarım gibi sürekli dinamik bir yapı gösteren alanların izlenmesinde büyük bir avantaj sağlamaktadır. Bundan önceki çalışmalar çoklu zamanlı uydu görüntüleri ile yapılan tarımsal ürün desen sınıflandırmasının tek zamanlı uydu görüntüsüne göre daha yüksek doğruluk verdiğini göstermektedir ([Hu vd., 2019](#)). Çok zamanlı görüntülerle farklı fenolojik evrelere sahip farklı ürünler tespit edilebilirken, yakın fenolojik evrelere sahip farklı ürünler de birbirinden ayırt edilebilmektedir ([Foerster, Kaden, Foerster & Itzerott, 2012](#)).

Avusturya'da 2016-2017 yılları arasında kalan tarım sezonunda, bir kışlık sekiz yazlık olmak üzere dokuz tarımsal ürünün üç farklı sezonda Sentinel-2 görüntüleri ile sınıflandırma çalışması yapılmıştır. Birinci sezon mart başı nisan sonu arasında olup sınıflandırma başarımları oranı %50, ikinci sezon mayıs başı haziran sonunda olup sınıflandırma başarımları oranı %73, üçüncü sezon ise tüm tarımsal sezonu kapsayıp sınıflandırma başarımları oranı %95 seviyelerine kadar çıkmıştır ([Vuolo, Neuwirth, Immitzer, Atzberger & Ng, 2018](#)).

Farklı tarımsal ürünler göz önüne alınarak, uzaktan algılamadaki birçok metot değerlendirilerek, görüntülerde spektral ve spektral-uzamsal özelliklerin kullanımı ve sonuçları farklı çalışmalarda araştırılmıştır ([Vuolo vd., 2018](#)). Normalize edilmiş fark bitki örtüsü (Normalized difference vegetation index, NDVI) ve gelişmiş bitki örtüsü indeksi (Enhanced vegetation index, EVI) gibi indeksler bitkilerin fenolojik gelişimleri hakkında bilgi vermekte olup, bu indeksler sayesinde farklı tarımsal sezonlarda yetişen bitki türleri birbirinden ayırt edilebilmektedir ([Zhang, Kang, Xu & Zhang, 2020](#)). Normalize edilmiş fark su indeksi (Normalized difference water index, NDWI) bitkilerde bulunan su içeriğinin tespiti ve ürün sınıflandırmasında verimli olarak kullanılan indekslerden biridir ([Li vd., 2013](#)).

Çok zamanlı uydu görüntülerinin kullanımının yanı sıra tarımsal ürün desen sınıflandırma başarımlarını etkileyen faktörlerden biri de sınıflandırma işleminde kullanılan spektral bantlar ve bu bantlardan üretilen çeşitli indekslerdir. İngiltere'de Nottingham bölgesinde yapılan ürün desen sınıflandırmasında sadece RED, NIR ve SWIR bantları ile yapılan sınıflandırma başarımlarının %94.1, sadece NDVI ve NDWI indeksleri ile yapılan sınıflandırma başarımlarının %92.7, Sentinel-2 uydusuna ait 13 spektral bant ile sınıflandırma yapıldığında ise bu başarımları oranı %98.8 olmuştur ([Zhang vd., 2017](#)).

Uydulara ait spektral, zamansal, mekânsal çözünürlük arttıkça ve çalışma alanının geniş olması durumunda, yapılacak bir sınıflandırma işlemi için görüntülerin manuel olarak belirlenmesi, indirilmesi, çeşitli görüntü işleme adımlarından geçmesi ve sınıflandırma işleminin yapılması hem çok zaman almakta hem de kimi durumlarda yüksek donanımlı bilgisayar teknolojisi gerektirmektedir. Gelişen teknoloji ile bu ve benzeri durumları kolaylaştıran birçok bulut tabanlı uydu görüntüsü ve coğrafi veri işleme platformu geliştirilmiştir. Coğrafi veri işleme platformlarında biri Google Earth Engine (GEE)'dir. GEE uygulaması görüntüleri işleme adımıyla yerelde veriyi saklamak ve işlemek yerine, bulut ortamında veriyi tutmayı ve işlemeyi sağlamaktadır. Bu sayede bilgisayar özelliklerine bakılmaksızın istenilen sayıda görüntü sayısı çok daha hızlı ve

kolay bir şekilde kullanılabilir (Aghlmand vd., 2021). Landsat 1-8, Sentinel-1-5, Modis vb. uydu görüntülerine GEE üzerinden ücretsiz bir şekilde erişim sağlanabilmektedir (Gorelick vd., 2017). Bu uydu görüntülerinin yanı sıra, farklı mekânsal çözünürlüklerde sayısal arazi modelleri, yağış, sıcaklık gibi iklim verileri ile arazi yüzey sıcaklık değerleri gibi küresel ölçekli birçok veriyi hizmete sunmaktadır.

Diğer bir platform ise Sinergise firması tarafından geliştirilen kullanıcılara belirli limitte açık ve ücretsiz olan Sentinel-Hub EO Browser platformudur (URL-2). Bu platform ile Landsat 1-8 uydularına ait görüntüler ile Sentinel 1-5 uydularına ait görüntülerin yanı sıra, Modis, Envisat gibi uydu görüntülerine de erişim sağlanabilir. Bu uydu görüntüleri ile çalışma alanına ait hazır gerçek renk, yalancı renk, NDVI, NDWI vb. indeksler kullanılarak çeşitli temel düzeylerde analizler yapılabilmenin yanı sıra java tabanlı kod yazılarak da ileri düzeyde uzaktan algılama uygulamalarına imkân sağlanmaktadır.

Microsoft'un Planetary Computer platformu ise bir başka uzaktan algılama platformudur. Bu platformda da benzer uydu görüntüleri bulunup, Azure Blob depolamasını kullanarak kullanıcılar verilere bulut tabanlı olarak erişmekte olup java, python, .net, php gibi farklı dillerde kod yazma imkânı bulunmaktadır (URL-3).

Eo-Learn, veri bilimi, dünya gözlemi ile uzaktan algılama çalışmalarında makine öğrenmesini ve derin öğrenme algoritmalarını kullanan açık kaynak kodlu bir python kütüphanesidir. Eo-Learn Landsat, Sentinel, Modis, Envisat vb. görüntülere erişim imkânı sağlamaktadır. Eo-Learn ile uydu görüntüleri üzerindeki bulutlu alanların otomatik olarak tespiti ile maskelenmesi, arazi örtüsü sınıflandırması, tarımsal ürün desen sınıflandırması, obje tabanlı sınıflandırma, parsel sınırlarının otomatik tespiti, detay çıkarma, çözünürlük artırma gibi karmaşık uzaktan algılama çalışmaları, oluşturulan hazır iş modelleri ile makine öğrenmesi ve derin öğrenme kullanılarak yapılabilmektedir. Eo-Learn kütüphanesi uzaktan algılama verilerini depolamak ve işlemek için çok boyutlu diziler ve matrislerle işlem yapan bilimsel hesaplamalar için temel bir python kütüphanesi olan numpy kütüphanesini kullanmaktadır (URL-4). Bunun yanı sıra kullandığı başlıca kütüphaneler; gdal, rasterio, shapely, Fiona, cartopy ve pyproj kütüphaneleridir (URL-5). Eo-Learn kütüphanesi farklı işlemlere göre alt paketlere bölünmüş olup, kullanıcıya tüm kütüphaneyi kurmak yerine ihtiyaç duyduğu işleme göre alt paketlerden bir veya birkaçını kurma imkânı da sağlamaktadır (URL-6).

Eo-Learn kütüphanesi kullanarak tüm Slovenya ölçeğinde derin öğrenme ile arazi örtüsü sınıflandırması yapılmıştır. Yapılan bu sınıflandırma işleminde arazi örtüsü sınıflandırma işlemi tek bir görüntüden değil 10 gün aralıklı çok zamanlı Sentinel-2 görüntüleri ile yapılmış olup, sınıflandırma başarımları oranı %95.6 olmuştur (Lubej vd., 2019). Slovenya Tarım Piyasaları ve Kırsal Kalkınma Ajansından temin edilen parseller ve Eo-Learn kütüphanesi kullanılarak 13 tarımsal ürünün sınıflandırması yapılmıştır. Sınıflandırma sonucunda hafif gradyan artırma makineleri (Light gradient boosting machines, LightGBM) algoritması ile başarımları %72 olurken derin öğrenme ile ise bu oran %87'ye çıkmıştır (Račić vd., 2020).

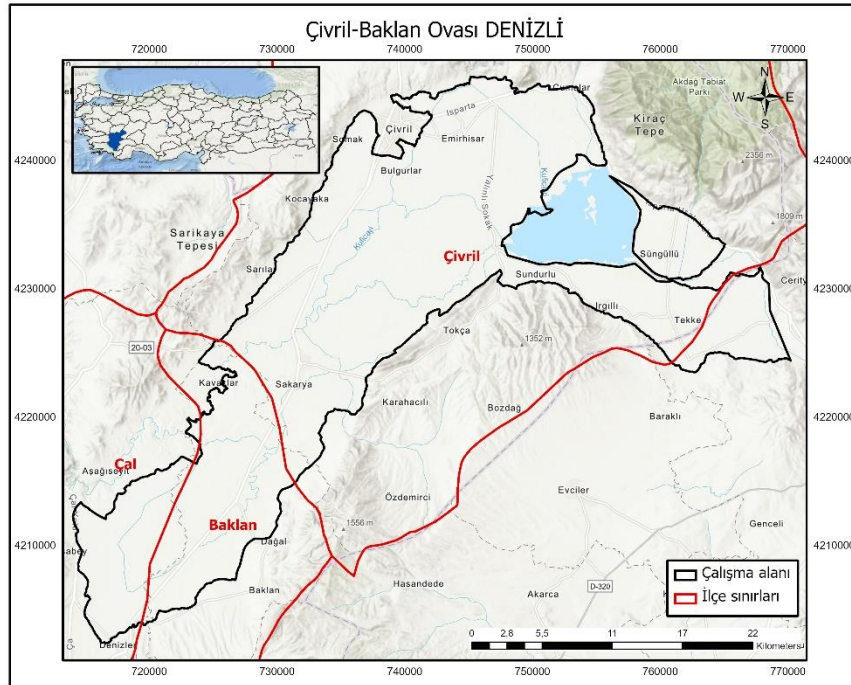
Tunus'un Medenine şehrinde yaklaşık 140 km²'lik bir alanda Eo-Learn kütüphanesi ile Sentinel-1 ve Sentinel-2 görüntüleri kullanılarak toprak nem tahmini çalışması yapılmıştır. Yapılan çalışma sonucunda rasgele orman (random forest) algoritması ile %88, XGboost algoritması ile %79, yapay sinir ağları ile ise %76 başarımları sonucuna ulaşılmıştır (Jarray vd., 2021).

2. Çalışma Alanı ve Kullanılan Veriler

2.1 Çalışma Alanı

Çalışma alanı Denizli ili Çivril, Baklan ve Çal ilçe sınırlarına giren Çivril-Baklan Ovası'nda yer almakta olup Çivril-Baklan-Toprak sulama birlikleri alanlarını içine alan yaklaşık 60 000 hektar gibi büyük bir alanı kapsamaktadır (Şekil 1). Yarı kapalı

havza niteliğinde olan Çivril-Baklan Ovası'nı, Ege Bölgesi'nin en önemli akarsuyu olan Büyük Menderes baştanbaşa sulayarak geçmektedir (Aksever & Eroğlu, 2016). Büyük Menderes Akarsuyu üzerinde Işıklı Gölü yer almakta olup ovanın tarımsal sulaması bu göl tarafından sağlanmaktadır. Çok büyük bir tarımsal alana sahip olan ovada; hububat (buğday, arpa, tritikale) ayçiçeği, haşhaş, mısır, şeker pancarı, yonca, bağ ve birçok çeşitten oluşan meyve ağacı en çok yetiştirilen ürünlerdir. Çalışma alanında 70 000'e yakın tarımsal üretim yapılan parsel bulunup ortalama parsel büyüklüğü 8 dekadır.



Şekil 1: Çalışma alanı.

2.2 Sentinel-2 Uydu Görüntüleri

Sentinel-2 (Sentinel 2a ve Sentinel 2b), Avrupa Birliği'nin Copernicus Çevre İzleme Programı kapsamında Avrupa Uzay Ajansı (European Space Agency, ESA) tarafından uzaya fırlatılan, 5 günlük çekim sıklığı ve farklı konumsal çözünürlüklerde (10 m, 20 m, 60 m) 13 spektral bantta sahip, pasif sensörlü bir yer gözlem uydusudur. Sentinel-2 görüntülerinin çok sayıda spektral bant içermesi ve özellikle 5 günlük zamansal çözünürlüğe sahip olması, tarımsal alanların gözlemlenmesi ve tarımsal ürün deseninin tespiti ile değişimin incelenmesinde çok büyük bir avantaj sağlamakta olup bu çalışmada kullanılmıştır.

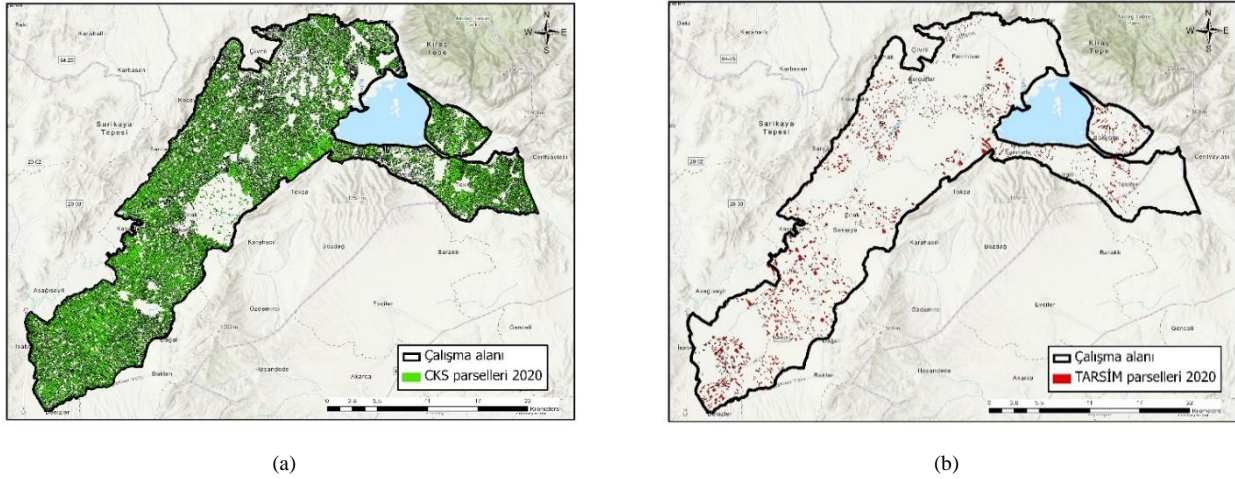
2.3 Yersel Referans Veriler

Çiftçi Kayıt Sistemi (ÇKS), çiftçilerin kimlik, arazi ve tarımsal ürünlerine yönelik olarak merkezi bir veri tabanında tutulan, sürekli güncellenen verilerin, izlenebildiği, kontrol edilebildiği, raporlanabildiği ve diğer sistemlerle entegre çalışabilen bünyesinde pek çok tarımsal desteklemelerin uygulanabildiği bir sistemdir. ÇKS'de bulunan bu parseller, parsellerin geometrisini içermesinin yanı sıra parsel için; il, ilçe, mahalle, ada/parsel numarası, zemin referans numarası, tarımsal kullanım durumu, parsel yüz ölçümü, ekili alan yüz ölçümü, ekili ürün bilgisi ve ekim tarihi ile hasat tarihi bilgilerini de içermektedir. Çalışma alanında, arazi çalışması yapılarak tarımsal ürün deseni belirlenecek her bir ürün için GPS yardımı ile yer doğruluk verisi toplanmıştır. Toplanan bu veriler referans alınarak, oluşturulan yöntemle ÇKS beyanlı parsellerde birçok farklı nedenden kaynaklı düzensizlik ve silme işlemleri gerçekleştirilerek, ÇKS beyanlı parsellerin yer doğruluk verisi haline getirilip sınıflandırma işleminde referans veri olarak kullanılması sağlanmıştır.

TARSİM'in açılımı "Tarım Sigortaları Havuzu" olup tarımsal faaliyet sürecinde olası risk ve hasarlara karşı ürün, hayvan ve

emeklerini güvenceye almayı sağlayan devlet destekli bir tarım sigortasıdır. 14/06/2005 tarihli 5363 sayılı "Tarım Sigortaları Kanunu" kapsamında kurulan Tarım Sigortaları Havuz İşletmesi A.Ş. çiftçilerin ürünlerini oluşabilecek hasarlara karşı güvence altına alınmasını amaçlar. TARSİM tarım sigortasını anlaşmalı acenteler aracılığıyla sahaya uzman göndererek yapmaktadır. TARSİM ile tarım ürünleri, hayvanlar, seralar, arı kovanları, tarımsal yapılar, tarım aletleri ve makineleri sigorta ile güvence altına alınır. Dolu, fırtına, hortum, sel, heyelan ve deprem, kar ağırlığı gibi doğal afetlerin yanı sıra yangın gibi doğal yoldan veya kaza ile oluşan durumlar hayvanlarda meydana gelebilen salgın hastalık sonucu oluşan zararlar TARSİM kapsamındadır.

Çalışma sonucunda test verisi olarak ayrılan ÇKS beyanlı parsellerle doğruluk analizi yapılmasının yanı sıra Tarım Sigortaları Havuz İşletmesi A.Ş. Genel Müdürlüğü'nden çalışma alanına ait, uzmanlar tarafında arazide yerinde görülmüş sigortalı parseller (TARSİM) temin edilmiştir. Temin edilen parsellere ait bilgiler arazide uzmanlar tarafından yerinden görüldüğü ve tıpkı ÇKS'deki gibi birçok bilgi ile özellikle ekili ürün bilgisini içerdiğinden referans veri olarak kullanılarak sınıflandırma sonucunda ikinci kere doğruluk analizi yapılmasına olanak sağlamıştır (Şekil 2).



Şekil 2: 2020 yılına ait beyanlı ve sigortalı parsellerin çalışma alanına dağılımı (a) ÇKS parselleri (b) TARSİM parselleri.

3. Yöntemler

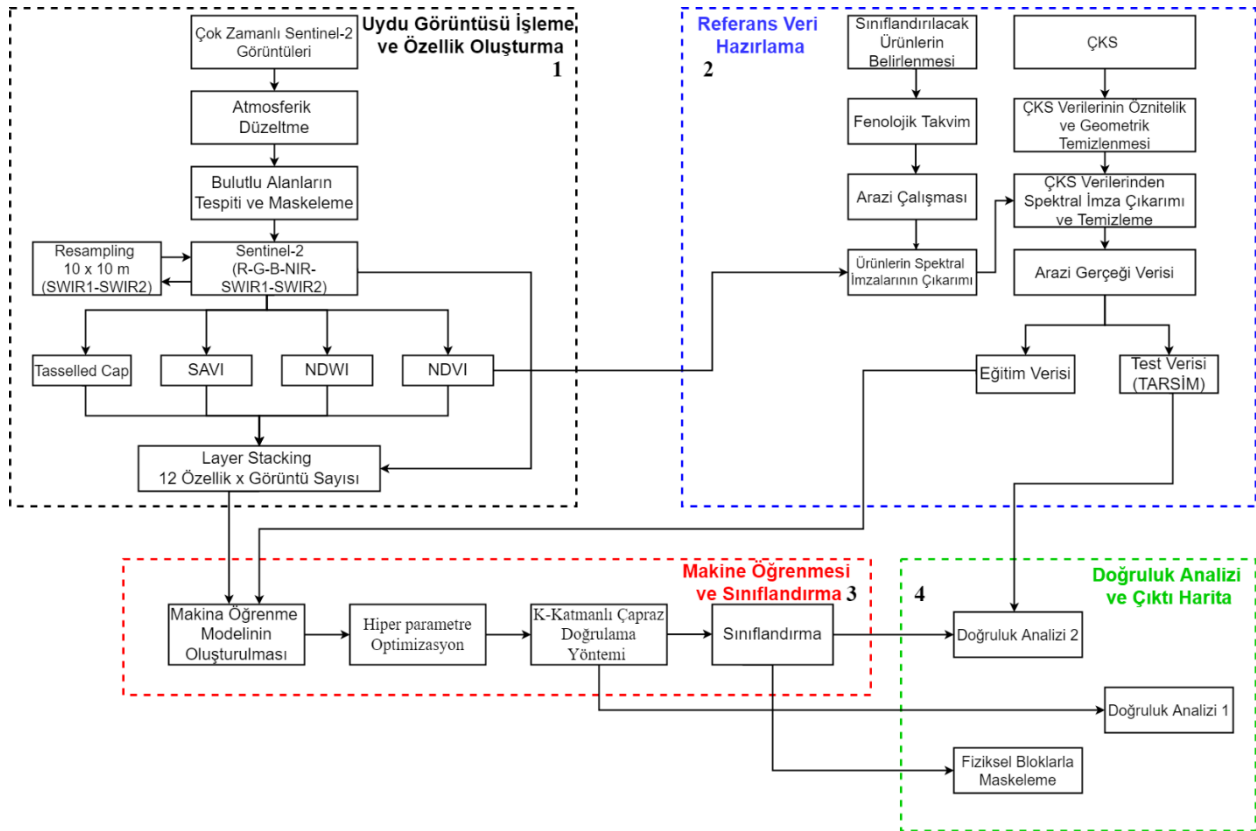
Eo-Learn kütüphanesi ve çok zamanlı Sentinel-2 görüntüleri ile tarım ürün deseni sınıflandırmasını gösteren akış diyagramı aşağıda gösterilmiştir (Şekil 3). Yöntem uydu görüntüsü işleme ve özellik oluşturma, referans veri hazırlama, makine öğrenmesi ile sınıflandırma ve doğruluk analizi olmak üzere 4 adımdan oluşmaktadır.

3.1 Uydu Görüntüsü İşleme ve Özellik Oluşturma


Sentinel-2 görüntülerine açık kaynak kodlu Eo-Learn python kütüphanesi içindeki *sentinelhub-py* python paketi kullanılarak erişim sağlanmıştır (URL-7). Bu paket ile Sentinel-Hub servislerine bağlanarak Amazon Cloud'da depolanan uydu görüntüleri temin edilmiştir (URL-8). Uydu görüntülerine ait bütün bilgiler (bantlar, oluşturan indeksler, bulut maskeleri vb.) numpy dizileri ile bütünleşik bir zaman serisi şeklinde her bir Eo-Patch'de depolanabilmekte olup python paketleri tarafından herhangi bir formatta okunabilen bilgiler de Eo-Patch'lerde saklanabilmektedir (URL-4).

Çalışmada kullanılacak Sentinel-2 görüntülerini her farklı tarih için ayrı olarak temin etmek yerine, Eo-Learn kütüphanesi ile başlangıç tarihi, bitiş tarihi ve görüntü alım aralığı gibi parametreler belirlenerek bütünleşik zaman serisi halinde bölümlenmelere (Eo-Patch) ayrılarak temin edilmiştir. Kullanıcı tarafından çalışma yapılacak alanın büyüklüğü, indirilecek tarih aralığının sıklığı ve işlem yapılacak bilgisayarın donanımı gibi değişkenler göz önünde bulundurulup, kullanıcı

tarafından bölümlenmelerin (Eo-Patch) boyutu değiştirilebilmektedir. Bu çalışmada Sentinel-2 L1C görüntüleri 01.01.2020-31.12.2020 tarihleri arasında 15 gün aralıklı 10×10 km boyutlu bölümlenmelere (Eo-Patch) ayrılarak temin edilmiştir. Temin edilen görüntülere ait alanın %30'dan fazlası bulut ile kaplı ise *Sen2cloudless* python kütüphanesi ile otomatik olarak çalışma dışında tutulmakta olup, bu eşik değeri değiştirilebilmektedir (Şekil 4).




Şekil 3: Sınıflandırma akış diyagramı.



Şekil 4: Çalışma alanına giren Eo-Patch'lerin görünümü.

Sentinel-2 L1C formatındaki görüntüler için ayrıca geometrik düzeltmeye gerek olmayıp, atmosferik düzeltme gerekmektedir (Zheng vd., 2017). Sen2Cor algoritması ile görüntüdeki piksel değerleri atmosfer üstü yansımaya değerlerinden (Top of atmosphere, TOA) atmosfer altı yansımaya değerlerine (Bottom of atmosphere, BOA) dönüştürülmüştür (Müller-Wilm, 2017). Uydü görüntülerinde atmosfer etkilerinden kaynaklı olarak ortaya çıkan bulutlar ve bulutlardan kaynaklı gölgeler görüntülerin analiz edilmesinde problem oluşturan temel gürültü kaynaklarıdır (Kalkan & Maktav, 2016). Bulutlardan

kaynaklı parlaklıklar ve gölgelerinin oluşturduğu karartılar veri analizini olumsuz etkilemektedir. Bu etkiler, NDVI vb. indekslerde değerlerin değişmesine, çeşitli analizler ile sınıflandırma işlemlerinde hataların oluşmasına neden olmaktadır (Zhu & Woodcock, 2012). Eo-Learn kütüphanesi içerisindeki Sen2cloudless paketi (URL-9) ile uydu görüntüsü üzerindeki bulutlar otomatik olarak tespit edilmiş ve maskelenmiştir (Şekil 5). Sen2cloudless bulut belirleme ve maskeleye paketi piksel tabanlı Sentinel-2 uydusuna ait B01, B02, B04, B05, B08, B8A, B09, B10, B11, B12 bantları ile LightGBM algoritmasını kullanarak çalışmaktadır (URL-10).



Şekil 5: Çivril Ovası'nda bulunan Işıklı gölü ve çevresindeki bulutların tespiti ve maskelenmesi.

Sınıflandırmanın doğruluğunu artırmak ya da başka bir deyişle arazi kullanımı ya da ürün desen sınıflarını birbirinden ayırt edilebilirliğini artırmak amacıyla ek veriler kullanılmaktadır (Üstüner, Şanlı & Abdikan, 2015). Sınıflandırma doğruluğu seçilen algoritma ve kullanılan uydu görüntüsüne bağlı olarak uygun spektral bant ve bu bantlardan üretilmiş indekslere de bağlıdır (Lu & Weng, 2007). Bu sebeple atmosferik düzeltme ile bulutlu alanların belirlenmesi ve maskelenmesi işlemlerinden sonra sınıflandırmaya dâhil olacak bantlar ve bu bantlardan üretilen indeksler belirlenmiştir. Özellikle tarımsal alanların izlenmesi ve tespitinde, kırmızı bant ile klorofile duyarlı olmaları sebebiyle yakın kızıl ötesi veya kırmızı kenar spektral bantları ve bu bantlardan elde edilen bitki indeksleri kullanılmakta olup başarılı sonuçlar elde edilmektedir (Eitel vd., 2011).

Çalışmada 10 metre mekânsal çözünürlüklü; mavi (B02), yeşil (B03), kırmızı (B04), yakın kızılötesi (B08) bantları ile 20 metre mekânsal çözünürlükten 10 metre mekânsal çözünürlüğe yeniden örneklenen kısa dalga kızılötesi-1 (SWIR-1) ve kısa dalga kızılötesi-2 (SWIR-2) bantları kullanılmıştır. Bu spektral bantlardan üretilen; NDVI, NDWI ve normalize edilmiş toprak ayarlı bitki indeksi (Soil adjusted vegetation indeks, SAVI) de sınıflandırmaya ek bant olarak dâhil edilmiştir. Bu indeksler dışında bilgi sağlayan yardımcı verilerden biri de Tasseled Cap olarak isimlendiren dönüşüm yöntemi verisidir. Tasseled Cap dönüşümü ilk Landsat MSS görüntüleri üzerinden tarım arazilerinin izlenmesi amacıyla geliştirilmiştir (Kauth & Thomas, 1976). Tasseled Cap dönüşümleri algılayıcıların ilgili bantlarını kullanarak vejetasyon indislerini zenginleştirme işlemidir. Tasseled Cap dönüşümünde kullanılan katsayılar belli algılayıcılar için sabit ve değişmezdir (Schowengerdt, 2006). Sentinel-2 uydusunun B02, B03, B04, B08, B11 ve B12 bantları kullanılarak parlaklık (brightness, TCB), yeşillik (greenness, TCG) ve nemlilik (wetness, TCW) indislerinin üç eksen boyunca dönüşümü sağlanarak, Tasseled Cap dönüşümleri yapılmıştır (Chen, Ren, Zhang & Wang, 2020).

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

$$NDWI = \frac{(GREEN-NIR)}{(GREEN+NIR)} \quad (2)$$

$$SAVI = \frac{(1+L)*(NIR-RED)}{(NIR+RED+L)} \quad (3)$$

$$TCW = 0.1509 \times B2 + 0.1973 \times B3 + 0.3279 \times B4 + 0.3406 \times B8 + 0.7112 \times B11 + 0.4572 \times B12 \quad (4)$$

$$TCB = 0.3037 \times B2 + 0.2793 \times B3 + 0.4743 \times B4 + 0.5585 \times B8 + 0.5082 \times B11 + 0.1863 \times B12 \quad (5)$$

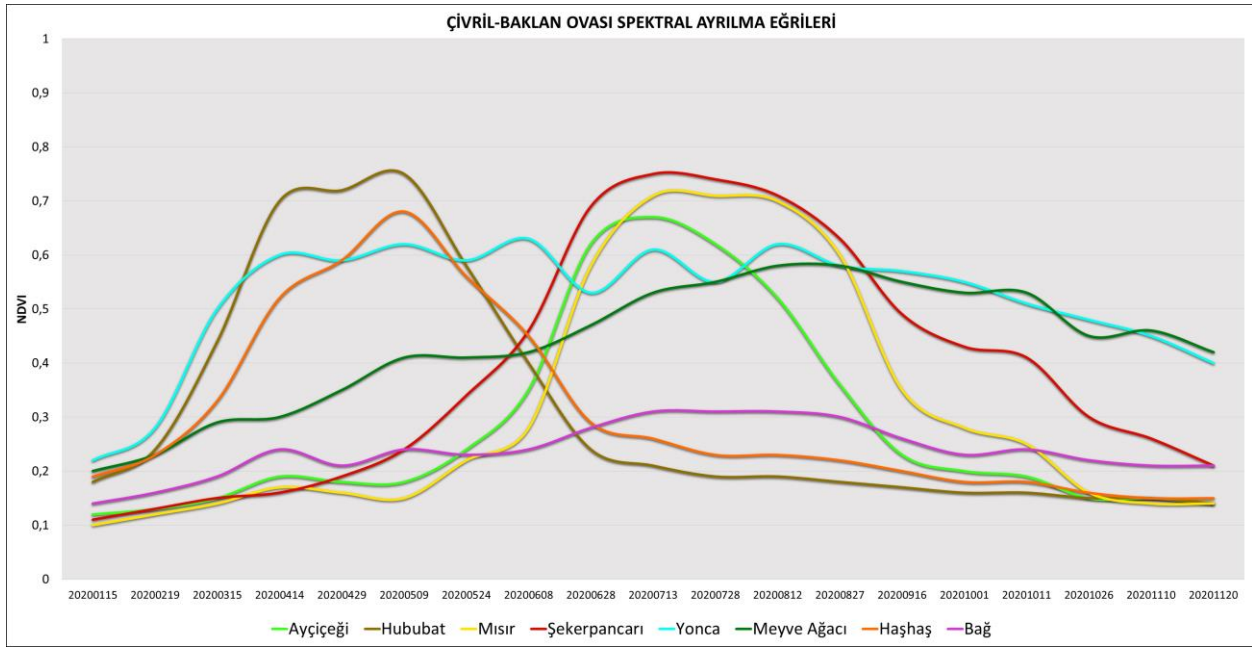
$$TCG = -0.2848 \times B2 - 0.2435 \times B3 - 0.5436 \times B4 + 0.7243 \times B8 + 0.0840 \times B11 - 0.1800 \times B12 \quad (6)$$

Sınıflandırma işleminde 15 gün aralıklı 24 farklı tarihte görüntü temin edilmiştir. Temin edilen bu görüntülerden 2., 3., ve 4. görüntülerdeki bulutlu alanlar, çalışma alanının %30'dan fazlasını kapsadığı için bu 3 görüntü sınıflandırma işlemine dahil edilmemiştir. Kalan 21 farklı tarihte çekilen her bir görüntü için; Sentinel-2 uydusuna ait B02, B03, B04, B08, B11, B12 ile bu bantlardan oluşturulan NDVI, NDWI, SAVI ve Tasseled Cap (parlaklık, yeşillik, nemlilik) dönüşümleri olmak üzere toplamda 12 farklı görüntü bandı oluşturulmuştur. Her bir görüntü çekim tarihine ait 12 farklı görüntü bandı numpy formatı şeklinde bir dizi haline getirilerek sınıflandırma işleminde 252 banttan oluşan görüntü katmanı kullanılmıştır.

3.2 Referans Veri Hazırlama

İşıkli Gölü'nü ve ovayı baştanbaşa geçen Büyük Menderes Nehri'nden dolayı Çivril-Baklan Ovası zengin tarımsal çeşit ve üretime sahiptir. Ovada tarla bitkilerinden buğday, arpa, ayçiçeği, şeker pancarı, haşhaş, mısır yem bitkilerinden ise yonca, fiğ, korunga yetişmektedir. Meyve üretiminin yoğun olarak yapıldığı ilçede elma ve üzüm üretimi yüksek seviyede iken bunları şeftali, kiraz, kayısı izlemektedir. Son 20 yılın ÇKS beyanlı parsellerinden oluşturulan istatistiki veri incelendiğinde bu ürünlerin ovanın %95'ini kapladığı sonucuna ulaşılmış aynı zamanda Çivril Tarım İlçe Müdürlüğü ile de görüşülüp bu istatistik teyit edilmiştir. Sınıflandıracak ürünlerde; buğday, arpa, tritikale ürünleri hububat sınıfı altında, yonca, fiğ, korunga ürünleri yonca sınıfı altında, ceviz, kiraz, şeftali, kayısı, vişne ve elma ağaçları ise meyve ağacı sınıfı altında toplanmıştır. Böylelikle Çivril-Baklan Ovası'nda, ovanın %95'lik tarımsal üretimini oluşturan hububat, haşhaş, ayçiçeği, mısır, şeker pancarı, yonca, üzüm ve meyve ağacı sınıfı için tarımsal ürün desen tespiti çalışması yapılmış geriye kalan %5'lik kısım göz ardı edilmiştir.

Arazi çalışmasından önce Çivril Tarım İlçe Müdürlüğü'nden sınıflandırması yapılacak ürünlere ait ekim, vejetatif gelişme, hasat öncesi bitkinin yeşil aksamının en belirgin olduğu tarih ve hasat tarihleri istenerek, sınıflandırması yapılacak ürünlerin fenolojileri hakkında bilgi sahibi olunmuştur. Çok zamanlı uydu görüntüleri ile yapılan sınıflandırma işlemi farklı fenolojik evreleri yakalayabilmekte olup, ürünlere ait fenolojik takvim, ürünlerin birbirleri ile zamansal olarak yakınlıkları ve uzaklıkları hakkında sınıflandırma öncesi ön bilgi edinimini sağlamaktadır. Fenolojik takvimin temininin ardından arazi çalışması yapılarak sınıflandırılacak ürünlere ait parsellerden GPS yardımıyla veri toplanmıştır. Çok zamanlı Sentinel-2 görüntülerinden üretilen NDVI bantları kullanılarak her bir sınıf için spektral ayrılma eğrileri oluşturulmuştur (Şekil 6).

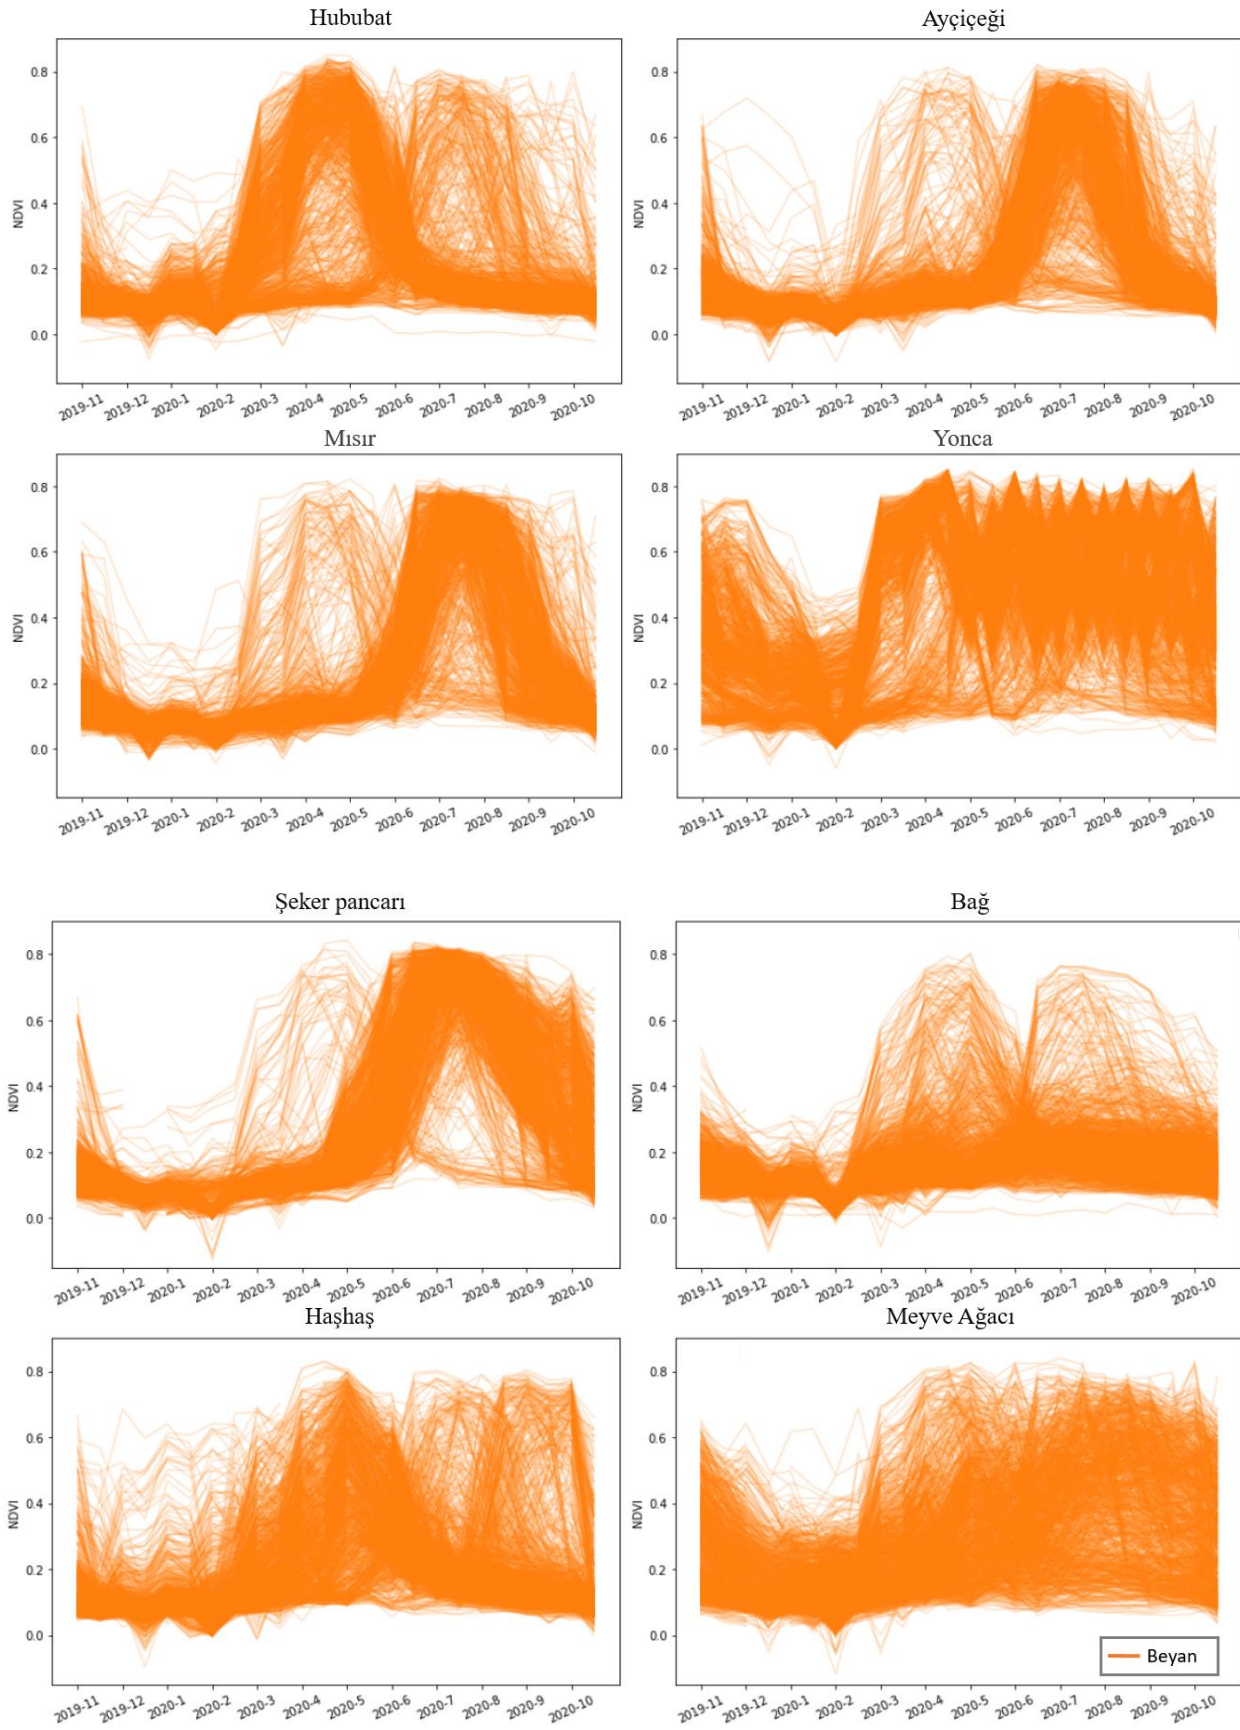


Şekil 6: Ürünlerin NDVI değerlerine göre zamansal değişimi.

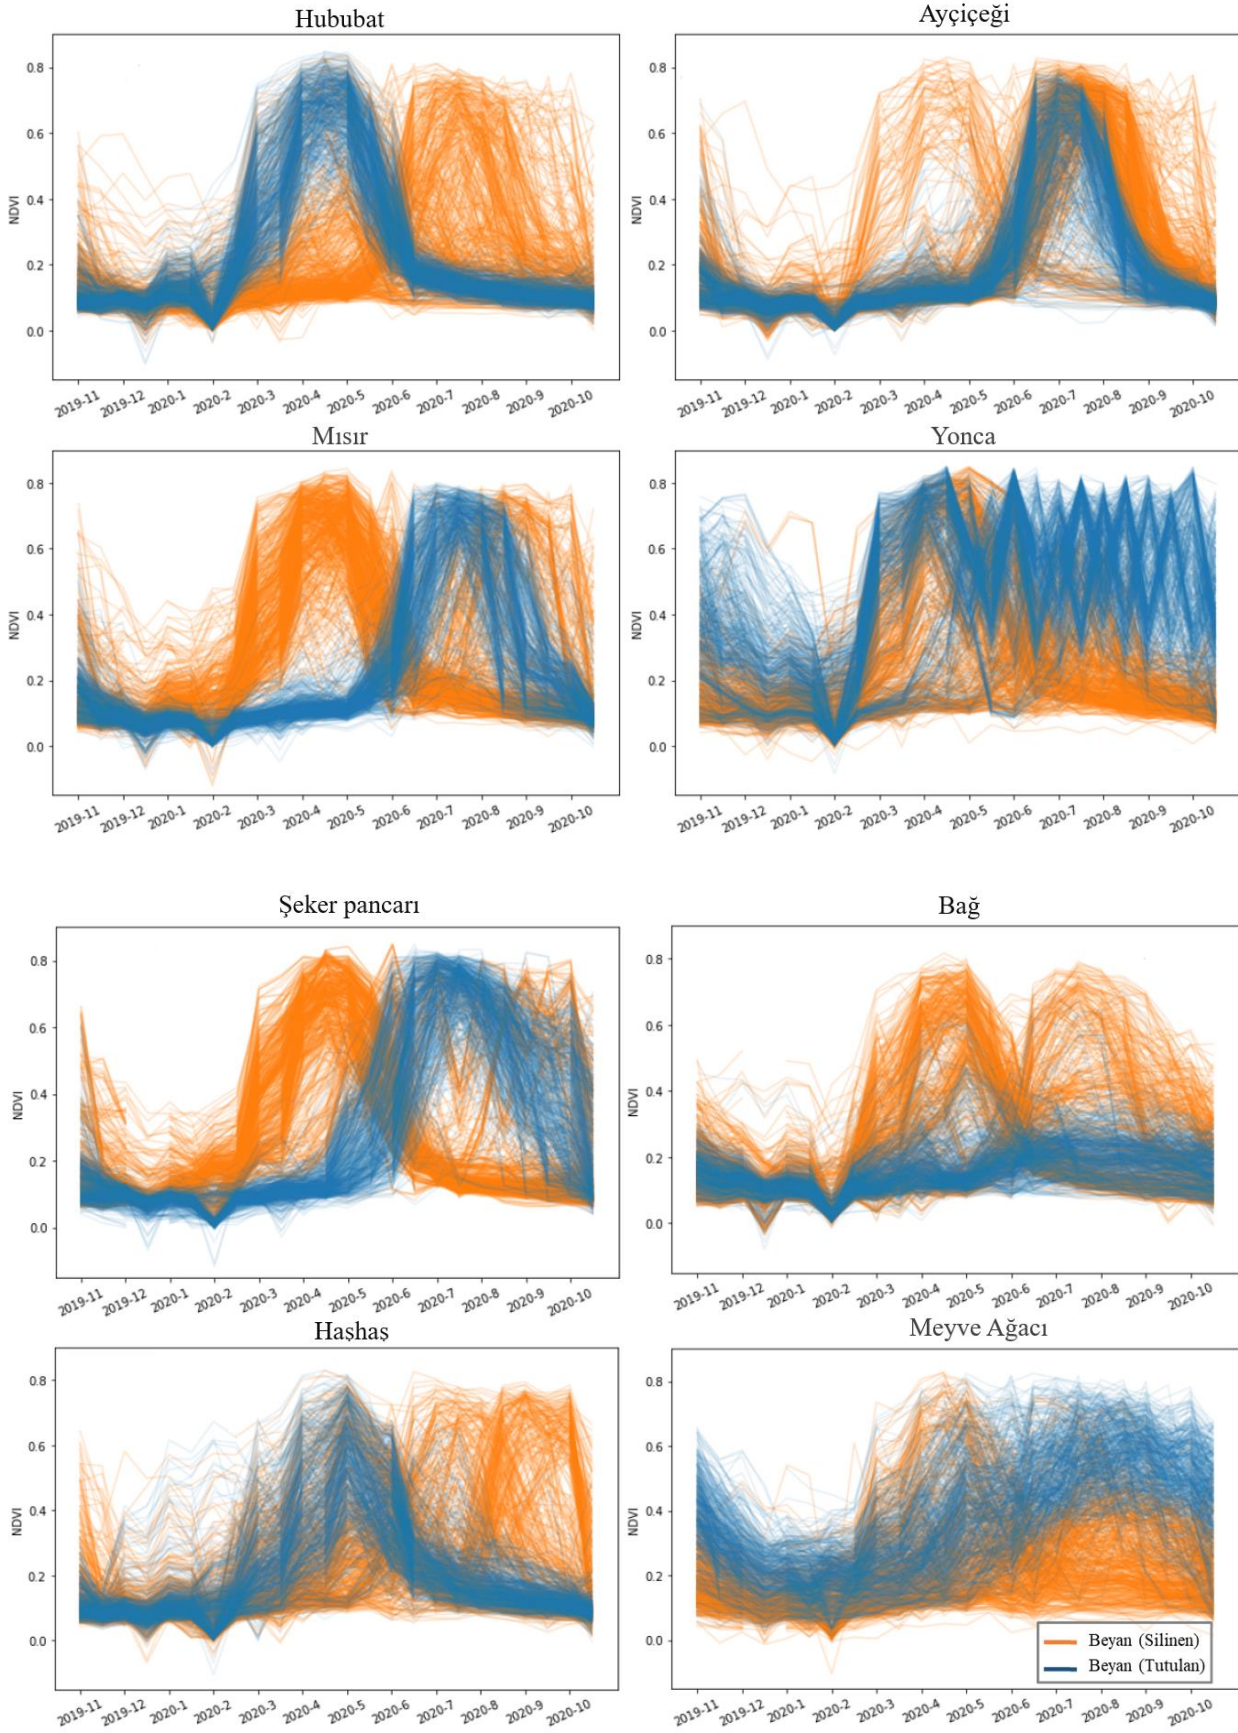
Arazi çalışması sonrasında Tarım ve Orman Bakanlığında ÇKS verileri temin edilmiştir. ÇKS verileri, arazi çalışmasından elde edilip üretilen spektral yansıma verileriyle değerlendirilerek arazi gerçeği verisi olarak kullanılacaktır. ÇKS parsellerinde yapılan incelemede birden fazla maliki olan parsellerde (hisseli mülkiyet) parsellerin fiziksel temsili ile ÇKS öznelik verisi arasında uyumsuzluk olduğu hissedar sayısından kaynaklı parsellerin tekrarlı tutulduğu belirlenmiştir. Veri girişinden kaynaklı aynı tarihlere ait birden fazla farklı ürün girişi yapıldığı, çiftçi tarafından beyan değişikliği başvurusunda bir önceki beyanın veri tabanında aktif olarak tutulup farklı tarihlere ait birden fazla ürün çeşidi bulunduğu da bir diğer öznelik kaynaklı problemidir. Tarım parselleri çizilirken ya da düzeltilirken üst üste binen parsellerin olduğu ve tarım dışı alanlarda beyanlı parsellerin olduğu tespit edilmiştir. ÇKS verisinin arazi gerçeği olarak kullanılmasından önce bu olası uyumsuzluk ve karışıklıkları gidermek amacıyla önce otomatik ve manuel olarak bir takım düzenleme ve silme işlemleri gerçekleştirilmiştir.

Düzenleme ve silme işlemleri gerçekleştirildikten sonra yapılan incelemede, ÇKS öznelik bilgisi ile ÇKS verisinin arazide temsil ettiği parseller (fiziksel yeryüzü) arasında ürün bilgisi göz önüne alındığında farklılık olduğu görülmüştür (Altun & Türker, 2021). Bazı parsellerin ÇKS’de beyan edilmesine rağmen ekilmediği, birçok parselde ise ÇKS’de beyan edilen ürün ile arazide ekilen ürün arasında farklılık olduğu tespit edilmiş olup, bu durumun ÇKS’deki en büyük problemlerden biri olduğu bilgisine ulaşılmıştır. NDVI indeksi bitki örtüsü fenolojisini incelemek için kullanılan popüler indekslerden biri olup, NDVI zaman serisi ile bitki örtüsünün yıl içerisindeki büyüme, gelişme ve hasadı ile ilgili bilgilere ulaşılabilmektedir (Mishra, Oza, & Sharma, 2017).

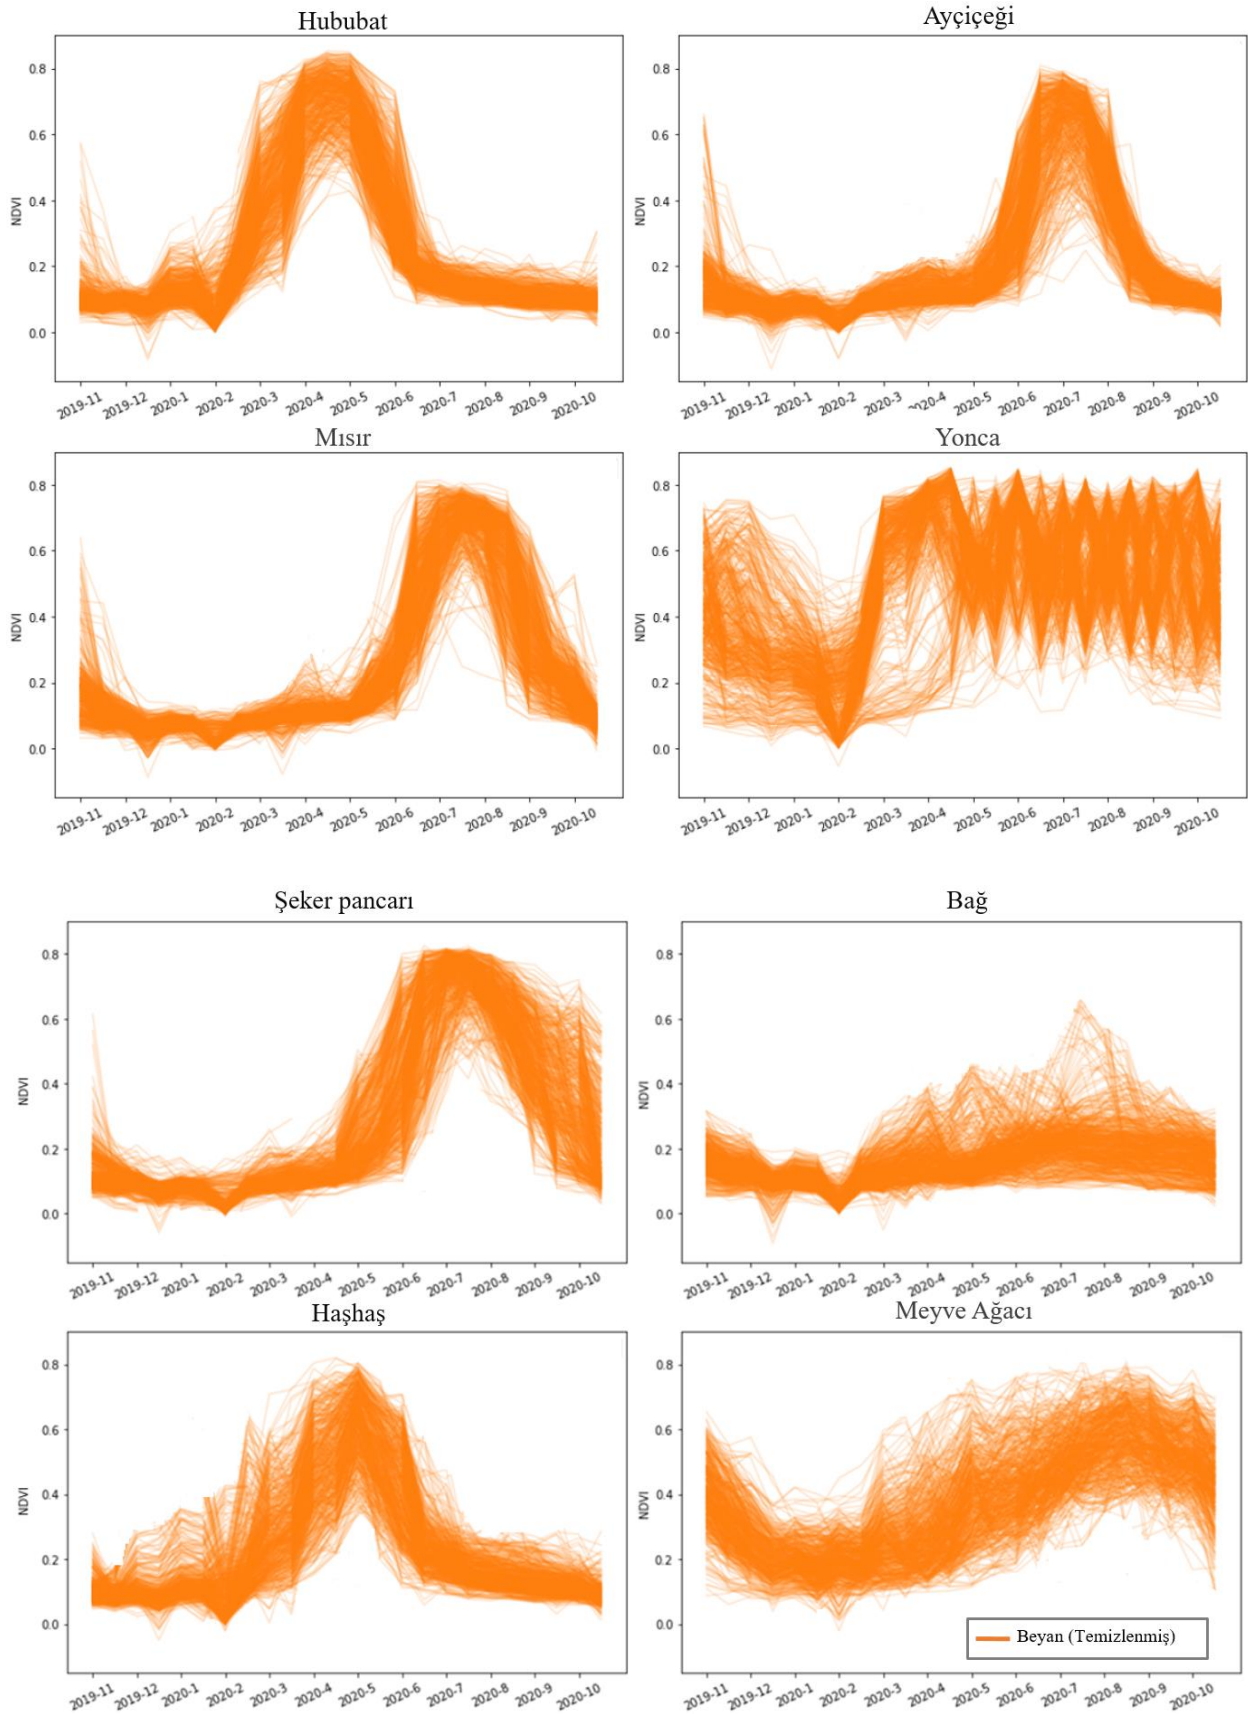
ÇKS beyanlı her bir parsel için NDVI değerleri belirlenmiş ve zaman serisi olarak bu işlem tekrarlanarak beyanlı her bir parsel için spektral ayrılma eğrisi oluşturulmuştur. Beyanlı parsellerde oluşturulan bu eğriler, arazi verilerinden üretilen spektral yansıma değerleri referans alınarak kontrol edilmiş, ÇKS kaydındaki bir parsel spektral olarak arazide bulunduğu tarih aralığında kendi türünün yansıma değerini vermemiş ise silinmiştir (Şekil 7, 8, 9). Bu işlem NDVI değerleri kullanılarak kural tabanlı yapılmış olup işlem sonrasında ÇKS parsellerinden çok sayıda arazi gerçeği verisi üretilmiştir. 2020 yılında Çivril-Baklan Ovası’nda Tarım Bilgi Sistemi veri tabanında 89 666 ÇKS beyanlı parsel olup parsellerdeki düzenleme ve silme işlemleri sonrası 16 021 parsel arazi gerçeği (referans) verisi olarak kullanılmıştır. Arazi gerçeği olarak kullanılacak parseller kendi içinde k-katmanlı çapraz doğrulama (k-fold cross validation) işlemine tabi tutulmuştur.



Şekil 7: ÇKS parsellerinin NDVI değerlerine göre zamansal değişimi.



Şekil 8: Ürünlere ait spektral ayrılma eğrileri referans alınarak silinen ve tutulan ÇKS parselleri.



Şekil 9: Arazi gerçeği olarak kullanılacak, temizlenmiş ÇKS parselleri.

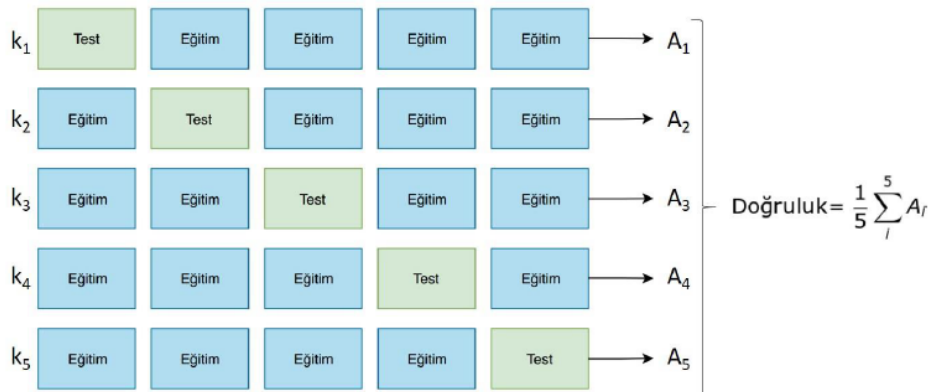
3.3 Makine Öğrenmesi ve Sınıflandırma

Son yıllarda veri boyutu ile çeşitliliğin hızla artması var olan algoritmalarda optimizasyonlara ve yeni algoritmaların

oluşturulmasına sebep olmuştur. Özellikle son yıllarda coğrafi bilgi sistemleri ve uzaktan algılamadaki verilerin boyutundaki artış ile küresel ölçekte çalışmalar yapılması kullanıcıları daha hızlı, optimum çalışan ve yüksek doğruluk elde edilmesini sağlayan yöntem arayışına sokmuştur. Özellikle sınıflandırma çalışmalarında kullanılacak modelin seçiminde, kullanılacak verinin boyutu, çeşitliliği, bilgisayar donanımının özellikleri, istenen sonucunun doğruluğu, işlem süresi gibi kriterler göz önüne alınarak optimum bir model belirlenmelidir.

LightGBM, Microsoft Distributed Machine Learning Toolkit (DMTK) projesi kapsamında 2017 yılında geliştirilmiş, karar ağacı algoritmalarına dayanan bir boosting algoritmasıdır (URL-11). Yöntemin isminden de anlaşılacağı üzere yüksek işlem hızına sahip bir algoritma olduğu için “Light” ön takısını almıştır (Üstüner, Abdikan, Bilgin & Şanlı, 2020). Diğer boosting algoritmaları ile karşılaştırıldığında; yüksek işlem hızı, büyük verileri işleyebilmesi, daha az kaynak (RAM) kullanımı, yüksek tahmin oranı, paralel öğrenme ve GPU öğrenimini desteklemesi gibi avantajları vardır (URL-12). LightGBM algoritmasını diğer algoritmalarından ayıran özellik verinin eğitilmesi aşamasında yaprak odaklı genişlemesidir (Ke vd., 2017). Yaprak odaklı strateji ile daha az hata oranına sahip olup daha hızlı öğrenme gerçekleşmektedir (Li vd., 2019). Yaprak odaklı büyüme stratejisi verinin az olduğu durumlarda modelin aşırı öğrenmesine sebebiyet verdiğinden büyük verilerle çalışmada daha uygundur. Sınıflandırma işleminde Eo-Learn kütüphanesi içinde bulunan LightGBM makine öğrenme algoritması kullanılmıştır. Hiperparametre optimizasyonu, bir makine öğrenmesi algoritması için belirlenen başarı kriterlerine göre en uygun parametre kombinasyonunu bulma işlemidir. Hiperparametre optimizasyonu ile, modelin yüksek başarıya ulaşması ve model karmaşıklığı dengelenerek aşırı öğrenme – eksik öğrenme dengesini sağlamak amaçlanmaktadır. Çalışmada en uygun parametreler, hızlandırma türü (boosting type): Özel değişken paketi (exclusive feature bundling, EFB); yapraktaki minimum veri sayısı (min_child_sample): 20; güçlendirilmiş ağaç sayısı (n_estimators): 20; maksimum derinlik (max_depth): 7, yaprak sayısı (num_leaves): 200; özelliklerin kümeleneceği maksimum bölütleme sayısı (max_bin): 255 olarak belirlenmiştir.

Sınıflandırma işleminde kullanılacak algoritmaya ait optimum parametre belirlendikten sonra k-katmanlı çapraz doğrulama yöntemi kullanılmıştır. k-katmanlı doğrulama yöntemi, modelin yüksek performansının rastgele olup olmadığının görülmesini sağlamaktadır. Bu yöntemde veri seti k sayıda parçaya bölünür ve k-1 adet alt küme modeli eğitmek için kullanılır, geriye kalan alt küme ise modelin doğruluğunu hesaplamak için kullanılmaktadır. Her seferinde farklı eğitim ve test verisi kullanarak işlem k defa tekrarlanır (Kohavi, 1995). Elde edilen doğruluk değerlerinin ortalaması modelin doğruluğunu temsil etmekte olup bu çalışmada k değeri 5 alınmıştır (Şekil 10). K değerinin 5 alınması sonucu 16 021 adet referans parselin %80’i olan 12 817 adedi eğitim %20’ si olan 3204 adedi test verisi kullanılmış olup her k (k_1, \dots, k_5) değeri için eğitim ve referans parseller belirlenen yüzdelerde rastgele otomatik olarak seçilmiştir.



Şekil 10: 5-katmanlı çapraz doğrulama (Üstüner & Şanlı, 2019).

3.4 Doğruluk Analizi ve Çıktı Harita

Sınıflandırma işlemi tamamlandıktan sonra doğruluk analizi yapılmış olup her bir sınıfa ait duyarlılık (Recall), kesinlik (Precision) ve kesinlik ile duyarlılık değerlerinin harmonik ortalaması olan F1 skor değerleri ile genel doğruluk hesaplanmış, k-katmanlı çapraz doğrulama yöntemi sonucu hata matrisi oluşturulmuştur (Şekil 11).

Mısır	0.92	0.00	0.07	0.00	0.00	0.01	0.00	0.00
Hububat	0.00	0.99	0.00	0.00	0.00	0.00	0.01	0.00
Ayçiçeği	0.21	0.00	0.78	0.00	0.00	0.00	0.00	0.00
Yonca	0.01	0.01	0.01	0.96	0.01	0.01	0.00	0.00
M. Ağacı	0.01	0.00	0.00	0.00	0.99	0.00	0.00	0.00
Ş.Pancarı	0.10	0.00	0.01	0.00	0.00	0.90	0.00	0.00
Haşhaş	0.02	0.34	0.01	0.01	0.00	0.00	0.63	0.00
Bağ	0.04	0.01	0.02	0.00	0.00	0.00	0.00	0.93
	Mısır	Hububat	Ayçiçeği	Yonca	M. Ağacı	Ş. Pancarı	Haşhaş	Bağ

Sınıflar	F1	Recall	Precision
Mısır	0.93	0.91	0.94
Hububat	0.97	0.99	0.95
Ayçiçeği	0.83	0.91	0.81
Yonca	0.97	0.96	0.98
Meyve Ağacı	0.96	0.96	0.96
Haşhaş	0.76	0.71	0.80
Şeker pancarı	0.91	0.91	0.91
Bağ	0.91	0.88	0.93
Genel Doğruluk: %93.5			

Şekil 11: Ürünlere ait F1, duyarlılık (Recall), kesinlik (Precision) değerleri ve hata matrisi.

Doğruluk analizine ait değerler incelendiğinde mısır, hububat, yonca, meyve ağacı, şeker pancarı ve bağ sınıfının 0.90 doğruluk değerinin üstünde olduğu görülmektedir. Mısır sınıfı ile yakın fenolojiye sahip ayçiçeği sınıfı, mısır sınıfı ile bir miktar karışmış olup 0.83 değerindedir. Hububat sınıfı ile çok yakın fenolojiye sahip olan haşhaş sınıfı ise 0.76 değerinde olup hububat sınıfı ile karıştığı sonucuna ulaşılmıştır. Çalışmanın genel doğruluğu ise %93.5'tir.

Arazi gerçeği verisi haline getirilen ÇKS beyanlı parsellerle k-katmanlı çapraz doğrulama yöntemi ile doğruluk analizi yapılmasının yanı sıra, çalışma alanı sınırları içerisinde ÇKS beyanlı parsellerle aynı yıl olan 2020 yılına ait 2042 adet sigortalı parsel ile (TARSİM) ikinci bir doğruluk analizi yapılmış olup, bu parsellerin hiçbiri eğitim verisi olarak sınıflandırma işleminde kullanılmamıştır. Yapılan ikinci doğruluk analizinde genel doğruluk ve kappa katsayısı değeri ile her bir sınıfa ait üretici ve kullanıcı doğruluk değerleri hesaplanmıştır. İkinci kere yapılan doğruluk analizinde genel doğruluğun %91.1 ve kappa katsayısının ise 0.89 olduğu görülmektedir (Şekil 12).

Sınıflandırma işlemi piksel tabanlı olduğundan her bir piksel ilişkili olduğu bir piksele atanmıştır. Piksel tabanlı bu çalışma sonucunda yerleşim alanları, yollar, ormanlık, sulak, kayalık vb. tarım dışı ve suni alanlar da girdi veri setindeki herhangi bir sınıfa atanmıştır. Sınıflandırma sonucunda s girdi veri seti ile ilişkili sadece tarımsal ürün deseni sınıflandırmasının kalması için, sınıflandırma sonucu çıkan raster veri, Tarım Reformu Genel Müdürlüğü tarafından Entegre İdare ve Kontrol Sistemi (Integrated Administration and Control System, IACS) projesi kapsamında oluşturulan fiziksel bloklar ve bu fiziksel bloklar içerisindeki tarım dışı kapsayan poligonlar kullanılarak maskelenmiş ve elimine edilmiştir (Şekil 13).

geçmesi gerekmektedir. Çalışmada 15 gün aralıklı Sentinel-2 görüntüleri kullanılmış bu görüntüler tek tek temin edilmek yerine Eo-Learn ile bütünleşik zaman serisi halinde bölümlenmelere (Eo-Patch) ayrılarak temin edilmiş olup hem görüntü seçimi hem de temin süresi göz önüne alındığında büyük kolaylık sağlanmıştır. Eo-Learn kütüphanesi ile sınıflandırma işleminde kullanılacak görüntülerin temini, atmosferik düzeltme, bulutlu alanların belirlenmesi ve maskelenmesi, görüntülerdeki bantlar kullanılarak indeks-özellik çıkarımı ve görüntülerdeki bantlar ile çıkarılan indekslerin birleşiminden oluşan görüntü yığını işlemleri açık kaynak kodlu kütüphane içerisindeki birbirine bağlı iş modelleri ile yapılmıştır.

Sınıflandırma işleminde referans veriler, makine öğrenme algoritmalarında oluşturulan modelin eğitiminde kullanılmaktadır. Referans verinin temini için arazi çalışması yapılması veya arazi çalışması yerine geçebilecek veriye ihtiyaç duyulmaktadır. ÇKS ile ülkemizdeki tarımsal faaliyetler kayıt alınmış olup, bu çalışmada uydu görüntüleri ile tarımsal ürün desen tespitinde referans veri olarak kullanılmıştır. Ancak ÇKS parsellerinin referans olarak kullanılmasından önce verilerin öznitelik ve geometrik olarak düzenleme ile silme işlemlerine tabi tutulması gerekmektedir. Bu işlemin ardından ikinci adım olarak sınıflandırma işlemi yapılacak her bir ürüne ait araziden veri toplanmış, çok zamanlı Sentinel-2 görüntülerinden üretilen NDVI bantları kullanılarak her bir sınıf için spektral ayrılma eğrileri oluşturulmuştur. Oluşturulan bu eğriler referans alınıp ÇKS parselleri temizlenerek arazi gerçeği verisi bir başka deyişle sınıflandırma işleminde kullanılacak referans parseller haline getirilmiştir.

Görüntülerin ön işleme işlemleri ile referans parsellerin hazırlanmasının ardından Eo-Learn kütüphanesi içerisindeki LightGBM algoritması kullanılarak tarımsal ürün desen sınıflandırması yapılmıştır. Yapılan sınıflandırma işlemi sonucu doğruluk analizleri incelendiğinde genel doğruluğun %93 seviyesinde olduğu ve yapılan çalışmanın yüksek doğrulukta sonuç verdiği görülmüştür. Mısır, hububat, yonca, meyve ağacı, şeker pancarı ve bağ sınıflarında doğruluğun %90'dan yüksek olduğu tespit edilmiştir. Ayçiçeği sınıfının %85.8 ve haşhaş sınıfının %76.5 seviyesinde çıkmasının nedeninin ise ayçiçeğinin mısır ile haşhaşın ise hububat ile bir miktar karışmasından kaynaklı olduğu sonucuna varılmıştır.

ÇKS parsellerinden oluşturulan referans parseller kullanılarak k-katmanlı çapraz doğrulama yöntemi ile doğruluk analizinin yanı sıra arazide uzmanlar tarafından yerinde tespiti ve ölçümü yapılan sigortalı parseller (TARSİM) kullanılarak ikinci bir doğruluk analizi, bir başka deyişle çalışmanın sağlaması tekrar yapılmıştır. Sınıflandırma işlemine eğitim verisi olarak girmemiş bu verilerle yapılan doğruluk analizinden, genel doğruluk ve kappa katsayısı sırasıyla %91.1 ve 0.89 olarak hesaplanmıştır. Sınıflandırma işleminde eğitim verisi olarak kullanılmamış bu verilerle yapılan doğruluk analizinin yüksek çıkması, maliyet ve zaman kaybını minimuma indirerek araziye hiç gitmeden ya da çok az sayıda parsel giderek ÇKS veri tabanı içerisindeki parsellerin belirli düzenleme ve silme işlemleri ile arazi gerçeği verisi haline getirilip sınıflandırma işleminde referans veri olarak kullanılabilceği göstermiştir.

Python tabanlı açık kaynak kodlu Eo-Learn kütüphanesi ile görüntülerin temin edilmesinden ön işlemlerine, makine öğrenmesinden doğruluk analizine kadar olan birbiriyle bağlı ve entegre iş modelleri ile zamandan tasarruf edilerek karmaşık işlemler yüksek güven aralığında yapılmış olup özellikle büyük alanlarda ve çok sayıda görüntü içeren çalışmalarda büyük bir avantaj sağlayacağı sonucuna ulaşılmıştır.

Gelecek çalışmalarda, tarımsal ürünlerin sınıflandırması işleminde farklı bantlar ile indeksler dâhil edilerek, özellikle yakın fenolojiye sahip olup birbiriyle karışan ürünlerin ayrıştırılarak yüksek doğruluk elde edilmesi amaçlanmaktadır. Ayrıca çalışmada kullanılan makine öğrenme algoritmasının yanı sıra derin öğrenme algoritması da gelecek çalışmalara dâhil edilecektir.

Teşekkür

Çalışmada kullanılan ÇKS verileri ile fiziksel bloklar için Tarım Reformu Genel Müdürlüğüne, TARSİM verileri için Tarım Sigortaları Havuz İşletmesi A.Ş.'ye Eo-Learn kütüphanesi ile ilgili destek olan Sinergise firmasına teşekkür ederiz.

Yazar Katkısı

Fatih Fehmi Şimşek: Fikir, Tasarım, Veri toplama ve işleme, Literatür taraması, Yazım. **Süleyman Savaş Durduran:** Tasarım, Denetleme, Makale değerlendirme.

Çıkar Çatışması Beyanı

Yazar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

Kaynaklar

- Aghlmand, M., Kalkan, K., Onur, M. İ., Öztürk, G., & Ulutak, E. (2021). Google Earth Engine ile arazi kullanımı haritalarının üretimi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 38-47.
- Aksever, F., & Eroğlu, A. (2016). Çivril-Baklan (Denizli) Ovasında Yeraltısuyuna İklim Değişikliğinin Etkisi. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(1), 11-26.
- Altun, M., & Türker, M. (2021). Çoklu Zamanlı Sentinel-2 Görüntülerinden Tarımsal Ürün Tespiti: Mardin-Kızıltepe Örneği. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 21(4), 881-899.
- Chen, L., Ren, C., Zhang, B., & Wang, Z. (2020). Multi-sensor prediction of stand volume by a hybrid model of support vector machine for regression kriging. *Forests*, 11(3), 296.
- Eitel, J. U., 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.
- Foerster, S., Kaden, K., Foerster, M., & Itzerott, S. (2012). Crop type mapping using spectral-temporal profiles and phenological information. *Computers and Electronics in Agriculture*, 89, 30-40.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- Hu, Q., Sulla-Menashe, D., Xu, B., Yin, H., Tang, H., Yang, P., & Wu, W. (2019). A phenology-based spectral and temporal feature selection method for crop mapping from satellite time series. *International Journal of Applied Earth Observation and Geoinformation*, 80, 218-229.
- Jarray, N., Abbes, A. B., Rhif, M., Chouikhi, F., & Farah, I. R. (2021). An open-source platform to estimate Soil Moisture using Machine Learning Methods based on Eo-learn library. *2021 International Congress of Advanced Technology and Engineering (ICOTEN)*. IEEE.
- Kalkan, K., & Maktav, D. (2016). Landsat-8 Görüntülerinden Gölge ve Bulut Belirleme. *VI. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, Adana.
- Kauth, R. J., & Thomas, G. S. (1976). The tasselled cap--a graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. *LARS symposia*, Indiana, ABD.
- 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*, 30.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conference on Artificial Intelligence*, Quebec, Kanada.
- Li, W., Ding, S., Chen, Y., Wang, H., & Yang, S. (2019). Transfer learning-based default prediction model for consumer credit in

- China. *The Journal of Supercomputing*, 75(2), 862-884.
- Li, W., Du, Z., Ling, F., Zhou, D., Wang, H., Gui, Y., Sun, B., & Zhang, X. (2013). A comparison of land surface water mapping using the normalized difference water index from TM, ETM+ and ALI. *Remote Sensing*, 5(11), 5530-5549.
- 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., Batič, M., Kadunc, M., Milčinski, G., Peressutti, D., & Zupanc, A. (2019). Spatio-Temporal Deep Learning: Application to Land Cover Classification. *Living Planet Symposium*, Ljubljana, Slovenya.
- Mishra, S., Oza, M. P., & Sharma, S. A. (2017). Crop phenology identification using NDVI time-series and its dissemination using WebGIS. *38th Asian Conference on Remote Sensing*, Yeni Delhi, Hindistan.
- Müller-Wilm, U. (2017). Sen2Cor configuration and user manual. Ref. S2-PDGS-MPC-L2A-SUM-V2.4, 1, 9-12.
- Račić, M., Oštir, K., Peressutti, D., Zupanc, A., & Čehovin Zajc, L. (2020). Application of temporal convolutional neural network for the classification of crops on Sentinel-2 time series. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 43.
- Schowengerdt, R. A. (2006). *Remote sensing: models and methods for image processing*. Elsevier.
- Üstüner, M., Abdikan, S., Bilgin, G., & Şanlı, F. B. (2020). Hafif gradyan artırma makineleri ile tarımsal ürünlerin sınıflandırılması. *Turkish Journal of Remote Sensing and GIS*, 1(2), 97-105.
- Üstüner, M., & Şanlı, F. B. (2019). Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması. *Jeodezi Ve Jeoinformasyon Dergisi*, 7(1), 1-10.
- Üstüner, M., Şanlı F. B., & Abdikan, S. (2015). Spektral band ve bitki indeksi seçiminin ürün deseni sınıflandırma doğruluğuna etkisi: karşılaştırmalı analiz. *TUFUAB VIII. Teknik Sempozyumu*, Konya.
- Vuolo, F., Neuwirth, M., Immitzer, M., Atzberger, C., & Ng, W. T. (2018). How much does multi-temporal Sentinel-2 data improve crop type classification?. *International journal of applied earth observation and geoinformation*, 72, 122-130.
- 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, 105618.
- Zhang, T., Su, J., Liu, C., Chen, W. H., Liu, H., & Liu, G. (2017). Band selection in Sentinel-2 satellite for agriculture applications. *2017 23rd international conference on automation and computing*. IEEE.
- Zheng, H., Du, P., Chen, J., Xia, J., Li, E., Xu, Z., Li, X., & Yokoya, N. (2017). Performance evaluation of downscaling Sentinel-2 imagery for land use and land cover classification by spectral-spatial features. *Remote Sensing*, 9(12), 1274.
- Zhu, Z., & Woodcock, C. E. (2012). Object-based cloud and cloud shadow detection in Landsat imagery. *Remote sensing of environment*, 118, 83-94.
- URL-1: <https://scihub.copernicus.eu/> (Erişim Tarihi: 6 Şubat 2022).
- URL-2: <https://www.sentinel-hub.com/explore/eobrowser/> (Erişim Tarihi: 6 Şubat 2022).
- URL-3: <https://planetarycomputer.microsoft.com/catalog> (Erişim Tarihi: 8 Şubat 2022).
- URL-4: <https://medium.com/sentinel-hub/introducing-eo-learn-ab37f2869f5c> (Erişim Tarihi: 8 Şubat 2022).
- URL-5: <https://github.com/sentinel-hub/eo-learn/> (Erişim Tarihi: 9 Şubat 2022).
- URL-6: <https://eo-learn.readthedocs.io/en/latest/> (Erişim Tarihi: 9 Şubat 2022).
- URL-7: <https://sentinelhub-py.readthedocs.io/en/latest/configure.html#sentinel-hub-configuration> (Erişim Tarihi: 15 Şubat 2022).
- URL-8: <https://github.com/sentinel-hub/sentinelhub-py/> (Erişim Tarihi: 15 Şubat 2022).
- URL-9: <https://github.com/sentinel-hub/sentinel2-cloud-detector> (Erişim Tarihi: 16 Şubat 2022).
- URL-10: <https://medium.com/sentinel-hub/improving-cloud-detection-with-machine-learning-c09dc5d7cf13> (Erişim Tarihi: 16 Şubat 2022).
- URL-11: <https://lightgbm.readthedocs.io/en/latest/index.html> (Erişim Tarihi: 19 Şubat 2022).
- URL-12: <https://www.veribilimiokulu.com/lightgbm/> (Erişim Tarihi: 19 Şubat 2022).